

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

JOSÉ DAVID ANZANELLO JÚNIOR

**ALOCAÇÃO ÓTIMA DE BANCOS
DE CAPACITORES EM SISTEMAS
DE DISTRIBUIÇÃO
CONSIDERANDO A
CRONOLOGIA DA OPERAÇÃO E
INCERTEZAS**

Porto Alegre
2019

JOSÉ DAVID ANZANELLO JÚNIOR

**ALOCAÇÃO ÓTIMA DE BANCOS
DE CAPACITORES EM SISTEMAS
DE DISTRIBUIÇÃO
CONSIDERANDO A
CRONOLOGIA DA OPERAÇÃO E
INCERTEZAS**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.
Área de concentração: Sistemas de Energia

ORIENTADOR: Prof. Dr. Sérgio Haffner

Porto Alegre
2019

JOSÉ DAVID ANZANELLO JÚNIOR

**ALOCAÇÃO ÓTIMA DE BANCOS
DE CAPACITORES EM SISTEMAS
DE DISTRIBUIÇÃO
CONSIDERANDO A
CRONOLOGIA DA OPERAÇÃO E
INCERTEZAS**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: _____
Prof. Dr. Sérgio Haffner, Doutor pela Universidade Estadual de Campinas – Campinas, Brasil

Banca Examinadora:

Prof. Dr. Walmir de Freitas Filho, UNICAMP
Doutor pela Universidade Estadual de Campinas – Campinas, Brasil

Profa. Dra. Mariana Resener, UFRGS
Doutora pela Universidade Federal do Rio Grande do Sul – Porto Alegre, Brasil

Prof. Dr. Roberto Chouhy Leborgne, UFRGS
Doutor pela Chalmers University of Technology – Göteborg, Suécia

Coordenador do PPGEE: _____
Prof. Dr. João Manoel Gomes da Silva Jr.

Porto Alegre, março de 2019.

DEDICATÓRIA

Dedico esta dissertação à minha mãe Ivete Ana Bavaresco Anzanello e ao meu pai José David Anzanello, que com muito carinho e apoio em todos os momentos, não mediram esforços para que eu chegasse até esta etapa na minha vida.

AGRADECIMENTOS

Ao professor Sérgio Haffner pela excelente orientação, disponibilidade e pelas oportunidades oferecidas, desde as primeiras disciplinas da graduação em Engenharia de Energia, ao Trabalho de Conclusão de Curso e ao longo da realização desta Dissertação.

À minha família, em especial aos meus pais Ivete e José David pelo amor e incentivo.

Aos amigos Fernando, Juliano e Ricardo, pelo apoio, momentos de descontração e companheirismo desde a época do pré-vestibular.

Aos amigos que as inúmeras tarefas do dia a dia não conseguiram separar: Akan, Gabriel, Gustavo, Kroth, Daniel, Pedro, Pitt e Possebon.

À Morgana pela constante companhia, carinho e incondicional apoio para a realização deste trabalho.

Aos professores do PPGEE por toda dedicação e à Miriam Rosek por todo o apoio oferecido. Aos colegas do LASEP e PPGEE, em especial ao Christian Alan, Eduardo Braga e Bibiana Petry, pelo apoio, críticas e sugestões no desenvolvimento deste trabalho.

Por fim, agradeço ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro e por tornar viável a minha dedicação em tempo integral ao Curso de Pós-Graduação.

RESUMO

Este trabalho propõe um modelo de compensação de potência reativa para a alocação ótima de bancos de capacitores (BCs) fixos e automáticos aplicado ao problema de planejamento da expansão de sistemas de distribuição considerando incertezas. A função objetivo considera a minimização dos custos de investimento e dos custos de operação (manutenção, perdas de energia e violações nos níveis de tensão). As incertezas na carga e nas gerações distribuídas, baseadas em fonte solar fotovoltaica, são consideradas no modelo através da geração de cenários representativos obtidos pela técnica de clusterização *K-means*. O modelo desenvolvido foi resolvido utilizando uma implementação baseada na meta-heurística Algoritmo Genético (AG). É realizada uma codificação que favorece a inclusão de forma explícita das restrições de investimento e das restrições no modo de operação das unidades automáticas dos BCs. O modelo é implementado por intermédio da integração do *software* OpenDSS com o MATLAB®, no qual os fluxos de potência são resolvidos via *COM Interface* com o OpenDSS. Um sistema de 23 nós foi utilizado nos testes para demonstrar o potencial de aplicação oferecido pela formulação proposta. O modelo foi validado através da comparação dos resultados obtidos através dos cenários representativos com os resultados obtidos utilizando 365 dias diferentes de operação. Os casos analisados e os resultados obtidos demonstram a robustez do modelo proposto e a flexibilidade oferecida pela codificação empregada.

Palavras-chave: Alocação ótima de bancos de capacitores, sistema de distribuição de energia elétrica, incertezas, algoritmo genético, OpenDSS.

ABSTRACT

This work proposes a reactive power compensation model for the optimal allocation of fixed and automatic capacitor banks applied to the expansion planning problem of power distribution systems considering uncertainties. The objective function considers the minimization of investment costs and operating costs (maintenance, energy losses and voltage level violations). The uncertainties in load and distributed generations, based on solar photovoltaic source, are considered in the model through the generation of representative scenarios obtained by the *K-means* clustering technique. The developed model was solved using an implementation based on the metaheuristic Genetic Algorithm. A codification is carried out that favors the explicit inclusion of the investment restrictions and the restrictions on the mode of operation of the automatic units of the capacitor banks. The model is implemented by integrating OpenDSS software with MATLAB[®], in which power flows are solved via COM Interface with OpenDSS. A 23-node system was used in the tests to demonstrate the potential application of proposed formulation. The model was validated by comparing the results obtained through the representative scenarios with the results obtained using 365 different days of operation. The analyzed cases and the results obtained demonstrate the robustness of the proposed model and the flexibility offered by the encoding performed.

Keywords: optimal capacitor placement, electric power distribution system, uncertainties, genetic algorithm, OpenDSS.

LISTA DE ILUSTRAÇÕES

Figura 1:	Exemplo de execução do algoritmo <i>K-means</i>	35
Figura 2:	Curva de carga típica e sua curva de duração.	36
Figura 3:	Carga em um horário típico (t_i) como um número triangular <i>Fuzzy</i> . 37	
Figura 4:	Processo de construção dos conjuntos LDCU e HLRU.	38
Figura 5:	Curva de duração da carga/preço e o modelo de incerteza relacionado.	39
Figura 6:	Curva de duração da carga e curva de múltiplos níveis de carregamento.	41
Figura 7:	Representação da geração de curvas de carga artificiais com variação máxima (Δ) de: (a) 30 % e (b) 70 %.	47
Figura 8:	Diagrama ilustrativo do modelo de otimização proposto.	49
Figura 9:	Instantes de efetivação dos custos de investimento e de operação. 51	
Figura 10:	Função de representação da violação dos limites de tensão.	56
Figura 11:	Fluxograma do AG.	58
Figura 12:	Codificação empregada para o modelo de alocação ótima de BCs. 60	
Figura 13:	Exemplo de uma solução candidata.	61
Figura 14:	Operadores do AG, representados por: (a) recombinação simples, (b) recombinação aritmética e (c) recombinação discreta.	65
Figura 15:	Sistema de distribuição de 23 nós	69
Figura 16:	Curvas de carga diárias típicas de consumidores industriais, comerciais e residenciais para dias úteis	70
Figura 17:	Curvas de carga diárias típicas de consumidores industriais, comerciais e residenciais para sábados	70
Figura 18:	Curvas de carga diárias típicas de consumidores industriais, comerciais e residenciais para domingos.	71
Figura 19:	Curvas de carga diárias geradas artificialmente para os nós 2, 3 e 23, respectivamente, em dias úteis, com Δ de 70%.	72

Figura 20:	Curvas de carga diárias geradas artificialmente para os nós 2, 3 e 23, respectivamente, aos sábados, com Δ de 70%.	72
Figura 21:	Curvas de carga diárias geradas artificialmente para os nós 2, 3 e 23, respectivamente, aos domingos, com Δ de 70%.	73
Figura 22:	Curvas de carga diárias geradas artificialmente para os nós 2, 3 e 23, respectivamente, ao longo de um ano.	73
Figura 23:	Cenários de curva de carga obtidas a partir do <i>K-means</i> com 5 <i>clusters</i>	74
Figura 24:	Cenários de curva de carga obtidas a partir do <i>K-means</i> com 3 <i>clusters</i>	77
Figura 25:	Curvas históricas de geração fotovoltaica para o ano de 2016.	79
Figura 26:	Cenários de geração fotovoltaica obtidos a partir do <i>K-means</i> com 5 <i>clusters</i> para o ano de 2016.	80
Figura 27:	Cenários de geração fotovoltaica simultâneos obtidos a partir do <i>K-means</i> com 5 <i>clusters</i> para os anos de 2013, 2015 e 2009, respectivamente.	82
Figura 28:	Histograma do perfil de tensão para o caso base sem GD, para: (a) 3 cenários e (b) 365 dias.	90
Figura 29:	Histograma do perfil de tensão para o caso base com GD, para: (a) 9 cenários e (b) 365 dias.	91
Figura 30:	Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo, para: (a) 3 cenários e (b) 365 dias.	94
Figura 31:	Histograma de 100 execuções da função objetivo no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo para amostras de população com: (a) 50, (b) 100 e (c) 200 indivíduos.	95
Figura 32:	Convergência da função objetivo para a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo.	95
Figura 33:	Convergência de 5 execuções da função objetivo para a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo.	96
Figura 34:	Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós com GD considerando a parcela de perdas da função objetivo, para: (a) 9 cenários e (b) 365 dias.	98

Figura 35:	Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de violações de tensão da função objetivo, para: (a) 3 cenários e (b) 365 dias.	100
Figura 36:	Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós com GD considerando a parcela de violações de tensão da função objetivo, para: (a) 9 cenários e (b) 365 dias.	102
Figura 37:	Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós com GD considerando as duas parcelas da função objetivo, para: (a) 9 cenários e (b) 365 dias.	105
Figura 38:	Histograma de 100 execuções da função objetivo no sistema de 23 nós com GD considerando as duas parcelas da função objetivo para amostras de população com: (a) 50, (b) 100 e (c) 200 indivíduos.	106
Figura 39:	Convergência da função objetivo para a alocação de BCs no sistema de 23 nós com GD considerando as duas parcelas da função objetivo.	107
Figura 40:	Convergência de 8 execuções da função objetivo para a alocação de BCs no sistema de 23 nós com GD considerando as duas parcelas da função objetivo.	107
Figura 41:	Comparação dos resultados obtidos para o sistema de 23 nós com GD, para: (a) caso base, (b) somente perdas, (c) somente violações de tensão, (d) perdas e violações de tensão.	109

LISTA DE TABELAS

Tabela 1:	Comparação entre algumas referências consultadas	26
Tabela 2:	Patamares para a representação das curvas de carga diárias.	42
Tabela 3:	Estados da carga.	43
Tabela 4:	Estados de geração eólica	44
Tabela 5:	Comparação dos resultados obtidos na geração de curvas de carga representativas através do <i>K-means</i> para curvas diárias com 24 valores e com 8 patamares.	76
Tabela 6:	Histórico de geração anual para a cidade de Porto Alegre	79
Tabela 7:	Probabilidade dos cenários de geração FV com 5 <i>clusters</i> referentes a Figura 26.	81
Tabela 8:	Probabilidade e geração de energia dos cenários de geração fotovoltaica referentes a Figura 27.	83
Tabela 9:	Probabilidade conjunta de cenários representativos da carga com $\mathcal{K} = 2$ e da GD com $\mathcal{K} = 5$	84
Tabela 10:	Comparação dos resultados obtidos através da combinação dos cenários representativos de curvas de carga e GDs através do <i>K-means</i> para curvas diárias com 24 valores e com 8 patamares.	86
Tabela 11:	Dados dos bancos de capacitores.	88
Tabela 12:	Resultados do caso base do sistema de 23 barras sem GD.	89
Tabela 13:	Resultados do caso base do sistema de 23 nós com GD.	90
Tabela 14:	Parâmetros adotados no AG.	92
Tabela 15:	Resultados da alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo.	93
Tabela 16:	Resultados da alocação de BCs no sistema de 23 nós com GD considerando a parcela de perdas da função objetivo.	97
Tabela 17:	Resultados da alocação de BCs no sistema de 23 nós sem GD considerando a parcela de violações de tensão da função objetivo.	99

Tabela 18: Resultados da alocação de BCs no sistema de 23 nós com GD considerando a parcela de violações de tensão da função objetivo.	101
Tabela 19: Resultados da alocação de BCs no sistema de 23 nós com GD considerando as duas parcelas da função objetivo.	104

LISTA DE ABREVIATURAS

ANEEL	Agência Nacional de Energia Elétrica
AG	Algoritmo Genético
BC	Banco(s) de Capacitores
CDI	<i>Clustering Dispersion Indicator</i>
CEEE-D	Companhia Estadual de Distribuição de Energia Elétrica
DE	<i>Differential Evolution</i>
GD	Geração Distribuída
HBMO	<i>Honey Bee Mating Optimization</i>
HLRU	<i>Hourly net Load Ramping Uncertainty</i>
IA	<i>Interval Arithmetic</i>
IEEE	<i>Institute of Electrical and Electronics Engineers</i>
LDCU	<i>Load Duration Curve Uncertainty</i>
MIA	<i>Mean Index Adequacy</i>
NSGA-II	<i>Non-dominated Sorting Genetic Algorithm</i>
PDF	<i>Probability Density Function</i>
PEM	<i>Point Estimate Method</i>
PNLIM	Programação não linear Inteira Mista
PRODIST	Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico
PSO	<i>Particle Swarm Optimization</i>
RO	<i>Robust Optimization</i>
SA	<i>Simulated Annealing</i>
SDEE	Sistema(s) de Distribuição de Energia Elétrica
SMC	Simulação Monte Carlo
TUSD	Tarifa de Uso do Sistema de Distribuição

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Objetivos	19
1.2	Metodologia	19
1.3	Contribuições	20
2	FUNDAMENTOS DE ANÁLISE DA OPERAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO	21
2.1	Análise determinística	21
2.2	Análise probabilística	24
2.2.1	Alocação de Bancos de Capacitores considerando incertezas	24
2.2.2	Técnicas de clusterização	32
2.2.3	Modelagem das incertezas	36
2.2.4	Obtenção de cenários utilizando técnicas de clusterização	40
3	MODELO PROPOSTO PARA ALOCAÇÃO DE COMPENSAÇÃO DE POTÊNCIA REATIVA	46
3.1	Avaliação da operação considerando cenários que descrevem a operação diária	46
3.2	Formulação do modelo empregado	49
3.2.1	Função objetivo	50
3.2.2	Restrições	54
3.2.3	Indicador de violação nos níveis de tensão	55
4	ALGORITMO GENÉTICO PARA A ALOCAÇÃO DE COMPENSAÇÃO DE POTÊNCIA REATIVA	57
4.1	Codificação empregada	59
4.2	Determinação da população inicial	62

4.3	Função de adaptação	64
4.4	Seleção	64
4.5	Recombinação	64
4.6	Mutação	66
4.7	Busca Local e Intensificação	66
5	VALIDAÇÃO E APLICAÇÃO DO MODELO PROPOSTO	68
5.1	Validação dos Cenários de demanda e GD	68
5.1.1	Sistema de distribuição de 23 nós	68
5.1.2	Cenários de curvas de carga representativas	70
5.1.3	Cenários de geração fotovoltaica	78
5.1.4	Cenários de combinação carga-GD	83
5.2	Modelo de compensação de potência reativa	87
5.2.1	Alocação de BCs - Apenas Perdas	92
5.2.2	Alocação de BCs - Apenas Violações de Tensão	98
5.2.3	Alocação de BCs - Função Objetivo completa	103
5.2.4	Alocação de BCs - Comparação dos resultados	108
6	CONCLUSÕES	111
6.1	Trabalhos futuros	113
	REFERÊNCIAS	114

1 INTRODUÇÃO

Entre os critérios técnicos considerados quando são realizados estudos de planejamento de sistemas de distribuição de energia elétrica (SDEE), está a redução das perdas de energia. A preocupação com as perdas dentro das concessionárias é constante, tendo em vista que as mesmas podem significar redução no faturamento. Outro critério levado em consideração nos estudos de planejamento é a manutenção dos níveis de tensão em regime permanente dentro da faixa adequada, definida no Módulo 8 do PRODIST (ANEEL, 2018). Sabe-se que um perfil de tensão adequado traz benefícios tanto para as distribuidoras quanto para os consumidores, uma vez que tem impacto sobre a redução das perdas de energia e aumenta a satisfação dos clientes com relação à qualidade da energia sendo fornecida. Ainda, manter os níveis de tensão dentro das faixas indicadas como adequadas pelo órgão regulador significa evitar compensações financeiras a serem pagas aos consumidores no caso de serviço inadequado (RESENER, 2016).

O estabelecimento de metas de expansão contemplando projetos que proporcionem melhoria nos indicadores é interessante tanto para os clientes como para as distribuidoras. Uma vez que há melhora na qualidade do produto e do serviço, existe impacto na redução dos custos de operação juntamente com a redução das compensações financeiras oriundas de índices inadequados. Por ter importante impacto financeiro, é desejável que os métodos envolvidos na obtenção dos indicadores de operação sejam capazes de representar da melhor maneira possível a realidade do sistema. Com isso, permite-se a tomada de decisões mais exatas acerca das melhorias prioritárias e necessárias na rede aumentando o retorno sobre o investimento bem como a satisfação dos clientes (LAUTENSCHLEGER, 2018).

Diante de um cenário de crescente demanda e de uma cobrança cada vez maior

por parte dos consumidores por um fornecimento de qualidade, o desenvolvimento de modelos e técnicas adequadas de solução para o problema de planejamento da expansão de SDEE é de grande importância para as empresas distribuidoras (RESENER, 2016).

O planejamento das redes de distribuição deve, ainda, considerar o crescente número de conexões de geração distribuída (GD) nos SDEE, o que trouxe novos aspectos técnicos a serem considerados nos estudos. Na maioria dos casos, os empreendimentos de GD costumam ser baseados em fontes de energia primária intermitente, como solar fotovoltaica e eólica, introduzindo uma incerteza operacional por ser uma geração não-despachável.

Historicamente, a representação da demanda nas redes é modelada por valores determinísticos. No entanto, os SDEE são de natureza probabilística, o que leva a obtenção de soluções determinísticas imprecisas. Portanto, a fim de obter uma solução mais precisa e de maior qualidade, é necessário desenvolver modelos probabilísticos para incluir as incertezas associadas a carga em redes de distribuição. Além disso, quando a rede contempla unidades de geração distribuída, é necessário que suas gerações, com caráter intermitente, sejam da mesma forma incluídas no modelo probabilístico (JANNAT; SAVIC, 2016).

Conforme Haghifam e Malik (2007) e Zeinalzadeh, Mohammadi e Moradi (2015), o acesso à curva de carga de consumo é um dos processos mais importantes e difíceis no planejamento e operação de SDEE. A carga nas redes de distribuição varia ao longo do tempo e pode ser estocástica por natureza. Entretanto, para a coleta de dados históricos ou em tempo real, um número limitado de equipamentos é utilizado. Campanhas de medição e técnicas matemáticas para a alocação da carga são utilizadas para estimar a carga em pontos onde não é possível mensurar a carga de maneira adequada. Para a estimativa de carga futura, são utilizados métodos de previsão de carga, que envolvem análises de curto, médio ou longo prazo. Como os resultados das técnicas de estimativa e previsão de carga não são exatos, é desejável utilizar abordagens adequadas para a consideração da incerteza na carga em análises de sistemas de distribuição

Na maioria dos estudos de planejamento de SDEE, as técnicas de solução assumem que a demanda de carga segue um padrão definido, representado por uma

curva de carga determinística ou por um número fixo de níveis de carregamento. Entretanto, conforme Mukherjee e Goswami (2014), na realidade a demanda de carga tem um significativo grau de incerteza e depende de muitos fatores, de tal forma que é impossível prever a carga real antes da ocorrência real. As previsões de carga, baseadas em registros históricos de consumo, podem prever uma imagem grosseira da situação provável, na qual o cenário real pode desviar do previsto por uma margem considerável. Com isso, ao invés de representar a carga por um número de níveis de carregamento definidos, a representação probabilística tem levado em consideração a incerteza agregada. Mukherjee e Goswami (2014) afirmam que a alocação de BCs, por exemplo, baseada em sistemas com padrões fixos de variação de carga, pode levar a soluções consideravelmente inferiores às obtidas quando é considerada a característica intrínseca de aleatoriedade da carga.

Nos últimos anos, conforme Assis *et al.* (2018), os sistemas de potência vêm experimentando um nível ainda maior de incertezas, as quais estão associadas ao aumento de fontes renováveis de energia conectadas à rede, tais como sistemas de geração solar fotovoltaica e eólica. Portanto, de acordo com Kanwar *et al.* (2017), ao lidar com a intermitência da geração de energia elétrica a partir de fontes renováveis, é imperativo considerar também a natureza estocástica da demanda da carga nos sistemas de distribuição. Tal fato requer a consideração de fatores vitais que causam variabilidade na demanda e na geração, ou seja, segmentação dos tipos de consumidores e seus padrões de consumo, variações sazonais e incertezas associadas tanto à demanda da carga quanto às gerações por fontes intermitentes.

Kanwar *et al.* (2017) afirmam que pelo fato da natureza introduzir incertezas tanto na geração de energia quanto na demanda das cargas em redes elétricas inteligentes, a modelagem a ser desenvolvida para lidar com estas incertezas deve ser guiada pelo histórico de eventos ocorridos durante o período de tempo para o qual os dados sintéticos devem ser gerados. Entretanto, a abordagem deve envolver um número adequado de informações estatísticas e distribuições de probabilidade com um número finito de momentos, a fim de manter uma fácil compreensão e aplicação. Para esse propósito, técnicas de clusterização podem ser úteis, por condensar as amostras de dados sintéticos, a fim de obter dados fiéis que possam representar com proximidade a ocorrência de eventos naturais. Além do mais, a definição do número

de cenários que representam o sistema deve ser adequadamente ajustada como uma ponderação entre a precisão e o esforço computacional decorrente das técnicas de solução.

Um dos métodos para garantir que a operação de uma rede de distribuição seja segura e confiável é o controle do fluxo de energia reativa. Ao determinar a potência instalada e a localização ideal dos bancos de capacitores (BCs), é possível melhorar o perfil de tensão da rede, reduzir as perdas de potência ativa, além de liberar a capacidade das linhas (JANNAT; SAVIC, 2016).

Os BCs representam uma solução inicial interessante para a redução das perdas pelo seu baixo custo de aquisição e facilidade na instalação comparado a outras alternativas ou equipamentos. Na prática os BCs podem ser instalados em diversos pontos da rede; sob o ponto de vista financeiro, a melhor localização e o número mínimo de BCs devem ser escolhidos, levando ao problema da alocação ótima de BCs. Em função da sua relevância prática e técnica, este problema tem sido estudado continuamente há décadas e resolvido utilizando diferentes modelos e métodos. A minimização das perdas de potência ativa, a minimização dos desvios de tensão e a minimização de custos são os principais critérios de otimização encontrados na literatura (RESENER, 2016; MUKHERJEE; GOSWAMI, 2014; HAGHIFAM; MALIK, 2007).

A alocação de BCs fixos e automáticos é aplicável a SDEE existentes de forma rápida e com baixo investimento. Além disso, a queda de tensão nos terminais dos alimentadores pode ser melhorada pela instalação de BCs. No entanto, a alocação inadequada pode reduzir os benefícios mencionados e até colocar em risco todo o controle da operação do sistema (OSKUEE; MILANI; RAVADANEGH, 2016).

O principal desafio na alocação ótima de BCs é a determinação da localização e potência dos capacitores fixos e automáticos para obter redução de custos com o melhor benefício técnico para o sistema. A complexidade desse problema depende do número de nós, tipos de capacitores ofertados e a forma como a carga e sua incerteza são representadas (HAGHIFAM; MALIK, 2007). Devido às características não-lineares da função objetivo e as elevadas não-convexidades, o problema da alocação ótima de BCs tornou-se um dos problemas mais desafiadores na área de sistemas de potência (KAVOUSI-FARD; NIKNAM, 2013).

1.1 Objetivos

Dentro deste contexto, o objetivo geral deste trabalho é propor um modelo de compensação de potência reativa para a alocação ótima de BCs fixos e automáticos aplicado ao problema de planejamento da expansão de SDEE considerando incertezas na carga e na GD e considerando a cronologia da operação dos BCs automáticos. Em função da natureza deste problema de expansão, o modelo foi desenvolvido com horizonte de curto prazo, sendo a expansão considerada em um único estágio.

No modelo proposto, a função objetivo considera a minimização dos custos de investimento (aquisição e instalação de equipamentos) e dos custos de operação, que correspondem a custos anuais de manutenção somados aos custos das perdas de energia e os custos das compensações pelas violações nos níveis de tensão, conforme (ANEEL, 2018).

Desta forma, os principais objetivos específicos deste trabalho são:

- obter cenários representativos da operação do sistema através de uma técnica de clusterização;
- elaborar uma análise de sensibilidade para definir o número adequado de cenários representativos;
- considerar a cronologia da operação do sistema com resolução horária;
- aplicar a metodologia proposta em um sistema de distribuição teste;
- verificar o modo de operação dos BCs automáticos com resolução horária;
- avaliar os impactos das parcelas da função objetivo de forma separada e conjunta.

1.2 Metodologia

O modelo de otimização desenvolvido foi resolvido utilizando uma implementação especializada baseada na meta-heurística Algoritmo Genético (AG). Para tanto foi realizada uma codificação que favorecesse a inclusão de forma explícita das restrições de investimento e das restrições no modo de operação das unidades automáticas dos BCs. O AG inclui um controle de diversidade explícito e busca local.

As incertezas na carga e nas GDs, baseadas em fontes renováveis intermitentes, são consideradas no modelo através da geração de cenários representativos obtidos

por uma técnica de clusterização (*K-means*). Cada cenário consiste em uma curva diária com resolução horária representando um dia típico de operação de todas as demandas e GDs. Para determinar o número de cenários representativos, foi realizada uma análise de sensibilidade avaliando a ponderação entre precisão e esforço computacional.

O modelo proposto é implementado por intermédio da integração do *software* OpenDSS com o MATLAB®, no qual os fluxos de potência são resolvidos via *COM Interface* com o OpenDSS. Um sistema de 23 nós foi utilizado nos testes para demonstrar o potencial de aplicação e a flexibilidade oferecida pela formulação proposta.

1.3 Contribuições

As principais contribuições desta dissertação são as seguintes:

1. modelo de otimização que considera as incertezas da carga e de gerações distribuídas oriundas de fonte solar na análise da operação diária do SDEE;
2. modelo de alocação de BCs que considera a variação diária do modo de operação do sistema com resolução horária e sequenciamento cronológico;
3. análise de sensibilidade para definição do número mínimo de cenários médios de operação para representar com boa fidelidade os resultados que seriam obtidos por todas as amostras. O modelo desenvolvido considera na função objetivo duas parcelas: custo das perdas ativas e custo das compensações das violações de tensão;
4. codificação desenvolvida para incluir explicitamente partes das restrições do modelo proposto no AG (limite de investimento e restrições associadas a forma de operação dos BCs automáticos);
5. na falta de dados de consumo horários reais, foi desenvolvida uma metodologia para a criação de curvas de carga sintéticas com variação definida.

2 FUNDAMENTOS DE ANÁLISE DA OPERAÇÃO DE SISTEMAS DE DISTRIBUIÇÃO

Neste capítulo é apresentada uma revisão dos modelos matemáticos e metodologias adotadas para resolver o problema da alocação de compensação de potência reativa, através de análise determinística e probabilística. É dado destaque para os trabalhos que contemplam a alocação ótima de BCs considerando a natureza probabilística das cargas e gerações distribuídas no modelo de otimização. São apresentadas também revisões sobre modelagem das incertezas e técnicas de clusterização aplicadas a geração de cenários de operação.

2.1 Análise determinística

Conforme Haffner (2008), os métodos de solução aplicados aos problemas de operação e expansão de sistemas elétricos de potência podem ser, de modo geral, segmentados em três categorias: métodos analíticos, métodos de otimização exata e métodos heurísticos. Usando uma abordagem de otimização exata, é possível representar explicitamente restrições, as quais juntamente com a garantia de otimalidade, tornam essa abordagem atraente. Nas décadas de 1980 e 1990, os métodos heurísticos foram amplamente utilizados e aplicados com sucesso no planejamento de grandes sistemas elétricos de potência, devido ao fato que restrições não-lineares e funções objetivos não-lineares podem ser facilmente consideradas, mesmo na resolução de complexos problemas de programação não linear inteira mista (PNLIM).

O problema da alocação ótima de BCs vem sendo estudado de forma contínua há décadas, tendo um grande número de trabalhos dedicados a este tópico. Os primeiros trabalhos apresentaram métodos analíticos para a solução do problema, dadas as

restrições computacionais quando os recursos eram caros ou mesmo indisponíveis (RESENER, 2016).

Entre os primeiros trabalhos acerca do tema está o método apresentado por Neagle e Samson (1956), onde foi proposta a determinação da localização e da capacidade de BCs fixos. A minimização das perdas para um nível de carregamento definido foi o objetivo adotado. O modelo do sistema, no entanto, considerou uma distribuição de cargas uniforme e um único tipo de condutor, desprezando as tensões nas barras e o custo dos BCs. Neste trabalho foi introduzida a "regra dos 2/3", a qual define que o capacitor deve ter potência nominal igual a 2/3 da potência reativa total do alimentador e deve ser alocado a 2/3 da distância entre a subestação e o final da rede de distribuição. Este método é simplista e válido somente quando as mesmas suposições podem ser feitas e para o mesmo alimentador do estudo proposto. Entretanto, conforme o trabalho de Lee e Grainger (1981), a aplicação dessa regra pode inclusive resultar em prejuízos quando considerada uma distribuição de carga reativa mais próxima da realidade e alimentadores com mais de um tipo de condutor na rede.

Os efeitos da alocação de capacitores fixos em redes de distribuição foram analisados na mesma linha de pesquisa por Cook (1959), mas considerando variação na carga. Na sequência de seu trabalho, Cook (1961) considerou também a inclusão simultânea de capacitores fixos e chaveados, pesquisa que foi posteriormente estendida por Schmill (1965).

Conforme Haque (1999) e Resener (2016), os métodos analíticos são aplicados de modo simples, entretanto a maioria deles considera a potência nominal do BC como variável contínua, sendo necessário o arredondamento para se obter uma solução factível, o que pode resultar em diferenças significativas no valor da função objetivo.

O método proposto em Cook (1959; 1961) foi generalizado no trabalho de Grainger e Lee (1981), considerando diferentes condutores e a inclusão de cargas não uniformemente distribuídas para a simulação em sistemas de distribuição radiais. Na sequência de seus trabalhos, Lee e Grainger (1981) consideraram a inclusão de capacitores chaveados e, complementarmente, um modelo que considera o cálculo das tensões nas barras através de um fluxo de potência (GRAINGER; LEE, 1982).

Nos métodos baseados em otimização exata, os problemas matemáticos são for-

mulados de modo que seja possível resolvê-los através de algoritmos exatos. Com a maior disponibilidade de recursos computacionais avançados, esses métodos ganharam destaque. A abordagem realizada por Baran e Wu (1989) utilizou um modelo PNLIM para alocar BCs fixos e chaveados, no qual a variação da carga foi modelada através de diferentes níveis de carregamento. O objetivo foi a minimização das perdas de potência ativa, assumindo restrições dos níveis tensão. O método foi validado em sistemas com 9 e 69 nós, apresentando bom desempenho.

Posteriormente, no trabalho de Chiang (1990a), o método apresentado por Baran e Wu (1989) foi ampliado, considerando que o custo dos BCs é representado por uma função não diferenciável, o que se deve ao fato de que capacitores são alocados com capacidades pré-definidas, e assim a potência nominal e os ajustes de controle são tratados como variáveis discretas. Na programação não linear, a função objetivo é geralmente aproximada por uma função diferenciável, tendo em vista que isso facilita a solução. Em contraste, a formulação proposta por Chiang (1990b) utilizou a meta-heurística SA (*Simulated Annealing*) para a solução do problema, na qual os autores afirmaram que o método é capaz de determinar a solução ótima global.

Utilizando o modelo proposto por Chiang (1990a), a alocação ótima de BCs foi resolvida através da meta-heurística Algoritmo Genético (AG) no trabalho de Boone e Chiang (1993). Os autores enfatizam que o AG não requer que a função objetivo do problema seja diferenciável. O mesmo sistema de 69 nós foi utilizado nos testes, demonstrando que o AG é eficiente para a determinação da região no espaço de busca que contém a solução ótima global do problema. Tais resultados incentivaram o uso do AG para a resolução do problema de alocação de BCs fixos e chaveados.

Conforme Jannat e Savic (2016), nos últimos anos, muitos métodos e algoritmos foram propostos para resolver o problema da alocação ótima de bancos de capacitores. A minimização das perdas de potência ativa, a minimização do desvio do perfil de tensão e a minimização de custos são os principais critérios de otimização encontrados na literatura. No entanto, a maioria dos artigos recentes têm se concentrado mais em diversificar as técnicas de otimização aplicadas e menos em aprimorar a metodologia e à abordagem da resolução dos problemas associados à alocação ótima de BCs.

Segundo Mukherjee e Goswami (2014), se os BCs forem alocados com localização

e capacidade instalada adequadas, a tensão do terminal de carga pode ser mantida dentro do limite aceitável e assim as perdas nas linhas e o custo total do sistema podem ser reduzidos. Como a demanda nos sistemas de distribuição pode variar com o tempo, os capacitores devem ser de natureza fixa e/ou automática, nos quais uma potência reativa mínima pode ser mantida conectada ao sistema através de capacitores fixos e cabe aos capacitores adicionais a função de ligar ou desligar conforme a demanda da carga variar.

A determinação da capacidade, localização e tipo dos capacitores é um problema de otimização complexo e requer informações sobre a variação da carga do sistema com o tempo. A alocação dos BCs pode melhorar os parâmetros de qualidade de energia e compensar parte das perdas ativas com a injeção de potência reativa. Além do mais, são mais baratos que gerações distribuídas e têm menos limites para instalação (ZEINALZADEH; MOHAMMADI; MORADI, 2015).

Na grande maioria dos trabalhos que abordam a alocação de BCs, o consumo das cargas tem sido modelado como uma quantidade determinística. No entanto, os sistemas de distribuição são de natureza probabilística, levando a soluções determinísticas imprecisas. Com isso, a fim de obter soluções de melhor qualidade e maior precisão, é necessário desenvolver modelos de otimização probabilística para incluir as incertezas associadas ao consumo nas redes de distribuição. Além disso, se a rede também contiver GDs, como gerações eólicas e solares fotovoltaicas, com caráter distintamente intermitente, é necessários que as mesmas sejam também inclusas no modelo probabilístico (JANNAT; SAVIC, 2016).

2.2 Análise probabilística

2.2.1 Alocação de Bancos de Capacitores considerando incertezas

A modelagem de incertezas na alocação ótima de bancos de capacitores é considerada em um número mais reduzido de trabalhos. A análise probabilística é capaz de representar a natureza aleatória de sistemas elétricos, considerando um grande conjunto de situações críticas e de chances de ocorrência. As incertezas podem abordar a carga, a GD, o preço de mercado da energia e os parâmetros da rede, sendo modeladas através de diversas formas: lógica *fuzzy*, funções densidade de probabilidade, do inglês *probability density function* (PDF), RO (*robust optimization*),

PEM (*Point Estimate Method*), DT (*Decision Theory*) e contar também com técnicas de agregação como o *K-means* (JANNAT; SAVIC, 2016; KANWAR et al., 2017).

O modo de solução dos modelos tem predominância de métodos heurísticos como os baseados em Algoritmo Genético (AG), TB (*Tabu Search*), IA (*Interval Arithmetic*), HBMO (*Honey Bee Mating Optimization*), PSO (*Particle Swarm Optimization*), DE (*Differential Evolution*), ISA (*Immune System Algorithm*), Differential Evolution (DE), CSA (*Cuckoo Search Algorithm*), NSGA-II (*Non-dominated Sorting Genetic Algorithm*), PGSA (*Plant Growth Simulation Algorithm*) ABC (*Artificial Bee Colony*) e ACO (*Ant Colony Optimization*). Alguns algoritmos de otimização clássica também têm sido aplicados na solução da alocação de BCs, tal como o MIP (*Mixed Integer Programming*) e MINLP (*Mixed Integer Nonlinear Programming*) (MUKHERJEE; GOSWAMI, 2014; ZEINALZADEH; MOHAMMADI; MORADI, 2015; JANNAT; SAVIC, 2016).

Nesse contexto, foi feita uma comparação mais abrangente de algumas importantes abordagens recentes, correlatas ao método proposto no presente estudo, as quais se encontram de forma sintetizada na Tabela 1.

Haghifam e Malik (2007) propuseram o uso do AG para a solução do problema de alocação ótima de BCs fixos e chaveados, sendo proposta uma nova codificação na qual o cromossomo tem duas linhas. A função objetivo considera a minimização do custo associado a energia de perdas do sistema e a instalação dos BCs. É utilizada a lógica *Fuzzy* para representar a incerteza associada à carga na formulação do problema, que é definida por curvas de duração. O método foi testado em um sistema de 37 nós e no sistema de 69 nós apresentado por Baran e Wu (1989). Os autores concluem que a metodologia proposta apresentou resultados satisfatórios para os estudos de caso propostos, entretanto a alocação de BCs automáticos foi considerada em apenas um dos casos propostos.

A aplicação de AG para a alocação ótima de BCs fixos também foi proposta por Raju e Bijwe (2008). O objetivo é minimizar as perdas de potência ativa satisfazendo as restrições de limite de tensão nos nós. A otimização considera também a posição dos taps dos transformadores. É utilizado um fluxo de potência por lógica *Fuzzy*, no qual são incorporadas as incertezas relativas ao modelo da carga e aos parâmetros

Tabela 1: Comparação entre algumas referências consultadas

Características		Referências ¹													**
		A	B	C	D	E	F	G	H	I	J	K	L	M	
Alocação	BC fixo	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	BC automático	✓		✓			✓								✓
	GD					✓		✓				✓			
Incerteza abordada	Carga	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	GD					✓			✓		✓	✓		✓	✓
	Preço				✓					✓				✓	
	Parâmetros da rede		✓												
Modelagem das incertezas	Lógica <i>fuzzy</i>	✓	✓				✓	✓							
	PDF			✓		✓			✓	✓	✓			✓	✓
	Clusterização										✓			✓	✓
	RO											✓			
	PEM				✓								✓		
Método de solução	AG	✓	✓	✓											✓
	Busca Tabu			✓											
	HBMO				✓										
	IA						✓								
	PSO					✓		✓	✓			✓			
	DE								✓						
	NSGA-II									✓	✓		✓	✓	
Sistema simulado	IEEE 37 nós	✓													
	IEEE 69 nós	✓		✓											
	30 nós		✓						✓						
	25 nós		✓												
	IEEE 123 nós		✓												
	948 nós (real)			✓											
	IEEE 9 nós				✓										
	IEEE 34 nós				✓										
	12 nós					✓									
	41 nós (Índia)					✓									
	141 nós (Venezuela)					✓									
	10 nós						✓								
	IEEE 33 nós							✓		✓		✓	✓	✓	
	94 nós (Portugal)							✓							
	18 nós								✓						
	28 nós (Sérvia)										✓				
23 nós														✓	

¹Referências:

A: (HAGHIFAM; MALIK, 2007)

B: (RAJU; BIJWE, 2008)

C: (PEREIRA JR, 2009)

D: (KAVOUSI-FARD; NIKNAM, 2013)

E: (JAIN; SINGH; SRIVASTAVA, 2014)

F: (MUKHERJEE; GOSWAMI, 2014)

G: (ZEINALZADEH; MOHAMMADI; MORADI, 2015)

H: (NAJAFI et al., 2016)

I: (OSKUEE; MILANI; RAVADANEGH, 2016)

J: (JANNAT; SAVIC, 2016)

K: (KANWAR et al., 2017)

L: (RAVINDRA; JAYARAM, 2017)

** técnica proposta nesta dissertação

M: (RAVADANEGH; OSKUEE; KARIMI, 2017)

da rede. A metodologia foi validada em um sistema equilibrado de 30 barras, um sistema desequilibrado de 25 nós e em um sistema de 123 nós do IEEE. Os autores elucidam que trabalhos anteriores não consideram as incertezas associadas à carga e aos parâmetros da rede, sendo esta a principal contribuição do método proposto. A aplicação demonstrou ser promissora à época da publicação, no entanto o tempo de processamento se mostrou elevado e os próprios autores consideraram aprimorar o método em publicações futuras.

Pereira Jr. (2009) utiliza uma meta-heurística multiobjetivo baseada em Busca Tabu e AG para resolver o problema da alocação ótima de BCs fixos e automáticos em SDEE. O método proposto visa reduzir o conflito, sob o aspecto físico, entre melhorar o perfil de tensão da rede de distribuição e reduzir custos de investimentos e perdas com a alocação de BCs. Com isso, a função objetivo trata as infactibilidades das magnitudes das tensões como objetivo adicional à minimização de custos. São utilizadas curvas PDF como base para a modelagem da incerteza inerente à carga. Entretanto, após o tratamento estatístico dos dados das curvas de carga utilizadas, são somente definidos patamares de carregamento para as simulações. O modelo proposto foi testado em um alimentador de 69 nós (Baran e Wu, 1989) e em um alimentador real de distribuição com 948 nós. O autor conclui que a análise probabilística das soluções da fronteira de Pareto encontradas pelos algoritmos proporcionam um estudo mais amplo sobre as condições operacionais frente ao comportamento incerto das cargas.

Kavousi-Fard e Niknam (2013) propuseram um método para a alocação ótima de BCs que utiliza o algoritmo evolucionário HBMO, baseado no processo de acasalamento das abelhas. A minimização das perdas de potência ativa, a melhoria nos níveis de tensão e a minimização do custo são as funções objetivos investigadas na abordagem proposta. Todavia, são alocados apenas BCs fixos, negligenciando a possibilidade da alocação de BCs automáticos. A incerteza na variação da carga é abordada no problema de forma estocástica, utilizando a técnica PEM (*Point Estimate Method*). A metodologia considera as incertezas associadas a previsão das parcelas ativas e reativas da carga, assim como os coeficientes da função custo, concomitantemente. No processo de otimização, as soluções obtidas pela fronteira de Pareto são armazenadas em um repositório. Na sequência, através de uma técnica

de clusterização baseada em lógica *Fuzzy*, o número de soluções do repositório é reduzido para intervalos pré-estabelecidos, a fim de facilitar a definição da melhor solução da fronteira de Pareto. A metodologia proposta foi implementada e testada em dois sistemas de distribuição teste do IEEE, com 9 e 34 nós. As soluções obtidas foram comparadas com a solução de outros trabalhos obtidos de maneira determinística, mostrando-se melhores em todos os objetivos analisados.

No trabalho de Jain, Singh e Srivastava (2014) é apresentada uma metodologia para a alocação simultânea de BCs e GDs baseadas em fonte eólica. A otimização é dada através da aplicação do algoritmo PSO, na qual a função multiobjetivo considera a minimização das perdas de potência ativa e reativa, a minimização dos desvios de tensão e a minimização das emissões ambientais. Um fluxo de potência probabilístico é utilizado para determinar o número de horas limite de violações de tensão/corrente por ano, considerando a variabilidade horária da carga, modelada por curvas PDF. No entanto, é gerada apenas uma curva PDF para os nós com o mesmo tipo de carga e não são consideradas as variações sazonais. Um método de sensibilidade também é utilizado na Fronteira de Pareto para ajustar a dimensão dos BCs e GDs para eliminar as violações. Os autores citam como principal contribuição do trabalho a possibilidade de utilização do método por parte das distribuidoras de energia elétrica para lidar com a aleatoriedade das cargas no tempo juntamente com a intermitência das gerações eólicas. Para testar o método proposto, os autores utilizaram um sistema de 12 nós e dados de sistemas reais com 41 nós (Índia) e 141 nós (Venezuela). As soluções obtidas utilizando o método proposto apresentaram uma redução das perdas de potência ativa entre 58-90% e redução dos desvios de tensão nos cenários simulados.

Em (Mukherjee e Goswami, 2014) é proposto um método para alocação de BCs fixos e chaveados que utiliza a técnica IA (*Interval Arithmetic*), uma abordagem que é empregada para colocar limites em erros de arredondamento e erros de medição, e assim desenvolver métodos numéricos que geram resultados confiáveis. A incerteza associada à carga é representada por lógica *Fuzzy*, na qual as variações são modeladas por limites inferiores e superiores em torno dos níveis base, porém considera apenas poucos patamares de carregamento para a representação da carga. A função objetivo considera a minimização dos custos das perdas e do investimento em BCs. A solução

do problema tem duas etapas, primeiro é definida a localização do BC, e após é aplicada a técnica IA para definir a capacidade nominal do mesmo. A validação da metodologia foi realizada apenas em um sistema de 10 nós. Os autores concluem que embora as soluções obtidas sejam satisfatórias, o método proposto deve abordar simultaneamente a localização e o dimensionamento dos BCs em trabalhos futuros.

Zeinalzadeh, Mohammadi e Moradi (2015) propuseram uma nova aplicação do algoritmo PSO (*Particle Swarm Optimization*) para determinar simultaneamente a alocação de capacitores fixos e a localização e dimensionamento de GDs. A função multiobjetivo tem como objetivos a minimização das perdas de potência ativa, maximização da estabilidade da tensão (habilidade do sistema em manter a tensão dentro da faixa de variação adequada quando há aumento de carga) e balanceamento das correntes nas linhas. A incerteza nas cargas é modelada utilizando lógica *Fuzzy*, porém não é detalhado como foi realizada a modelagem. O método utiliza as soluções ótimas da fronteira de Pareto para resolver o problema e um mecanismo baseado em lógica *Fuzzy* para extrair a melhor solução entre as três diferentes funções objetivo, devido à diferença existente entre os valores das mesmas. Para testar a metodologia proposta, foi utilizado um sistema de 33 nós do IEEE e um alimentador real de Portugal com 94 nós. Os resultados obtidos com a formulação proposta foram comparados com resultados obtidos por métodos que utilizaram os algoritmos SPEA (*Strength Pareto Evolutionary Algorithm*), NSGA-II (*Non-dominated Sorting Genetic Algorithm*), MODE (*Multi-Objective Differential Evolution*) e a combinação do algoritmo ICA (*Imperialist Competitive Algorithm*) com o AG. Os autores concluíram que o método proposto é mais efetivo e tem maior capacidade de encontrar soluções ótimas nos casos em que os BCs e GDs são dimensionados e alocados simultaneamente em uma otimização multi-objetivo, no entanto a alocação de capacitores automáticos não foi considerada.

Em (Najafi *et al.*, 2016) é proposto um método para alocação de BCs fixos em SDEE com a presença de GDs, utilizando os algoritmos PSO e DE (*Differential Evolution*). O método proposto utiliza um algoritmo de fluxo de potência que considera a presença de harmônicas, oriundas de cargas não-lineares dos sistemas teste e da geração eólica. A função objetivo é composta pela minimização dos custos decorrentes das perdas de energia e do investimento nos BCs. A carga é representada

por quatro patamares de carregamento e as incertezas associadas são modeladas por distribuições de probabilidade. São consideradas também as incertezas associadas às gerações eólicas, representadas por 6 cenários de geração com diferentes probabilidades de ocorrência. As simulações foram realizadas em sistemas teste de 18 e 30 nós e os resultados obtidos demonstram a eficácia do método, todavia, não foram comparados com os resultados de outros trabalhos. Os autores consideram necessária a inclusão das harmônicas na modelagem de problemas da alocação de BCs para minimizar problemas decorrentes de uma elevada distorção harmônica.

O método proposto por Oskuee, Milani e Ravadanegh (2016) utiliza o algoritmo multiobjetivo NSGA-II para obter as soluções não-dominadas da alocação de BCs em sistemas de distribuição e um mecanismo baseado em lógica *Fuzzy* para extrair a melhor solução da fronteira de Pareto. A metodologia considera as incertezas associadas à carga e ao preço de mercado da energia, modeladas por distribuição normal em torno de cenários com patamares de carregamento da carga e do preço da energia. A função multiobjetivo considera a minimização do custo das perdas e do investimento em BCs, minimização dos desvios de tensão e a maximização da estabilidade da tensão. É utilizada a rede teste de 33 nós do IEEE para a simulação da metodologia proposta. De acordo com os autores, os resultados mostraram que o método foi capaz de determinar a melhor solução entre os objetivos com efetividade, melhorando a qualidade da energia e reduzindo as perdas. No entanto, a ausência de capacitores automáticos pode ter limitado a obtenção de melhores resultados.

A otimização por intermédio do algoritmo NSGA-II para a alocação ótima de BCs também foi proposta por Jannat e Savic (2016). A metodologia contempla a alocação de BCs fixos em redes de distribuição com unidades de GD eólica e/ou solar fotovoltaica. As incertezas associadas à carga e às GDs são modeladas por distribuições de probabilidade e após é utilizada uma técnica de clusterização (*K-means*) para transformar a curva de duração em cenários de operação com diferentes probabilidades de ocorrência. A função multiobjetivo considera a minimização da soma dos desvios quadráticos de tensão e a minimização da capacidade instalada de capacitores. O método foi testado em um sistema de distribuição real da Sérvia de 28 nós, com base em dados medidos de irradiação solar e velocidade do vento para as GDs presentes no sistema. Os resultados apresentados determinam a localização,

tipo, número e capacidade dos capacitores a serem instalados, juntamente com as soluções obtidas para os dois objetivos abordados, entretanto, não foi considerada a inclusão de BCs automáticos.

Kanwar *et al.* (2017) apresentaram uma metodologia para a alocação ótima de BCs e GDs intermitentes e despacháveis, concomitantemente, de modo que sejam coordenadas em conjunto para obter um melhor desempenho nos SDEE. Foi proposto um modelo de otimização robusta de dois estágios, no qual as fontes de incerteza são modeladas por um conjunto de incertezas poliédricas, do inglês *polyhedral uncertainty set* (PUS), enquanto o problema de otimização é resolvido utilizando a meta-heurística PSO. A função objetivo é formulada para maximizar o lucro líquido da alocação dos BCs e GDs em termos do valor presente líquido (VPL) do sistema, sujeito às restrições operacionais em um horizonte de 20 anos. O estudo de caso contempla um sistema de distribuição teste do IEEE de 33 nós, modificado pela inclusão de geração eólica, fotovoltaica e microturbinas. Os resultados demonstraram que a metodologia proposta encontra boas soluções, sendo rentável no ponto de vista econômico com incremento nos níveis de tensão, mas que poderia ter sido superior. Os autores relatam que houve aumento na dependência de energia reativa, fato ocorrido pois a capacidade de BCs é limitada pelas condições de carga mais leve durante o horizonte de planejamento com o intuito de evitar sobretensões. Entretanto, caso capacitores automáticos tivessem sido alocados nos picos de carga, em adição aos fixos, o problema poderia ter sido amenizado.

Em (Ravindra e Jayaram, 2017) o problema da alocação ótima de BCs é abordado utilizando o algoritmo NSGA-II. A minimização das perdas, dos desvios de tensão e do carregamento nas linhas são os objetivos simultaneamente otimizados, sendo incluídas restrições para que as tensões nos nós e as correntes nos ramos estejam dentro de uma faixa de valores permitidos. A incerteza na variação da carga é abordada no problema de alocação utilizando o método PEM (*Point Estimate Method*), sendo consideradas as variações sazonais na modelagem. No entanto, o método não define claramente os intervalos de confiança para a geração dos cenários, o que requer múltiplas simulações para ajustar os parâmetros. A metodologia proposta foi testada na rede de testes do IEEE de 33 nós. Os resultados demonstram uma considerável melhoria no desempenho da rede e uma probabilidade mínima da ocorrência de vio-

lações nos níveis aceitáveis de tensão. Os autores consideram a inclusão de gerações solares e eólicas como objeto de pesquisa futura no método proposto.

Ravadanegh, Oskuee e Karimi (2017) propuseram um método multiobjetivo baseado no algoritmo NSGA-II para solucionar o problema da alocação ótima de BCs simultaneamente com a reconfiguração do sistema de distribuição e a alocação de GDs eólicas. Para obter soluções que se aproximem de características realistas, o trabalho aborda as incertezas relativas à modelagem da carga, ao preço de mercado da energia e a potência de saída variável das unidades de GD. Entretanto, a carga é modelada a partir de apenas uma única curva PDF e segmentada em 5 níveis de carregamento com diferentes probabilidades a partir da aplicação de uma técnica de clusterização. A função multiobjetivo é composta pela minimização do custo e dos desvios de tensão, o incremento na estabilidade da tensão e a minimização da emissão de poluentes. Um mecanismo baseado em lógica *Fuzzy* é utilizado para extrair a melhor solução da fronteira de Pareto. O sistema do IEEE de 33 nós foi utilizado para testar a metodologia proposta. Os autores concluem que os resultados obtidos validaram a efetividade e robustez do método.

2.2.2 Técnicas de clusterização

Conforme Jain (2010), a análise por intermédio de *clusters* é o estudo formal de métodos e algoritmos para agrupar ou clusterizar objetos de acordo com medidas ou características intrínsecas percebidas ou através da similaridade. O objetivo da clusterização é encontrar estruturas em dados e, portanto, é de natureza exploratória.

De maneira semelhante, Zalik (2008) define a clusterização como o processo de particionar ou agrupar um determinado conjunto de padrões em *clusters* disjuntos. Isso é feito de tal forma que os padrões no mesmo *cluster* são semelhantes e os padrões pertencentes a dois *clusters* distintos são diferentes. *Clusters* podem diferir em termos de sua forma, tamanho e densidade. Bradley *et al.* (1998) afirmam que a abordagem mais usual é ver a clusterização como um problema de estimativa de densidade. Um *cluster* ideal pode ser definido como um conjunto de pontos que é compacto e isolado.

Os algoritmos de clusterização podem ser divididos em dois grupos: hierárquicos e particionais. De acordo com Jain (2010), os algoritmos de clusterização hierár-

quicos recursivamente encontram *clusters* aninhados tanto em modo aglomerativo (começando com cada ponto em seu próprio *cluster* e mesclando o par de *clusters* mais similar sucessivamente para formar uma hierarquia de *clusters*) ou no modo divisivo (começando com todos os pontos em um *cluster* e recursivamente dividindo cada *cluster* em *clusters* menores). Em comparação com os algoritmos de clusterização hierárquicos, os algoritmos de clusterização particionais localizam todos os *clusters* simultaneamente como uma partição dos dados e não impõem uma estrutura hierárquica.

A forma mais simples de clusterização é a particional, que visa particionar um dado conjunto de dados em subconjuntos disjuntos (*clusters*) para que os critérios de clusterização sejam otimizados. A minimização do erro de clusterização é o critério mais amplamente utilizado, no qual para cada ponto é calculada sua distância quadrática do centróide do *cluster* correspondente e, em seguida, é computada a soma dessas distâncias para todos os pontos no conjunto de dados analisado (LIKAS; VLASSIS; VERBEEK, 2003).

Jain (2010) fez uma importante distinção entre métodos de clusterização e algoritmos de clusterização. Um método de clusterização é uma estratégia geral empregada para resolver um problema de clusterização. Um algoritmo de clusterização, por outro lado, é simplesmente uma instância de um método. Por exemplo, minimizar o erro quadrático é um método de clusterização, e há muitos algoritmos de clusterização diferentes, incluindo o *K-means*, que implementam o método de minimização do erro quadrático.

Um dos algoritmos de clusterização mais simples e populares, o algoritmo particional *K-means*, tem uma rica e diversificada história, uma vez que foi descoberto independentemente em diferentes campos científicos. Alguns autores atribuem que o algoritmo foi originalmente proposto por Macqueen (1967). De acordo com Jain (2010), apesar do fato de que o *K-means* foi proposto há mais de 50 anos e milhares de algoritmos de clusterização foram publicados desde então, o *K-means* ainda é amplamente utilizado. Isso explica a dificuldade em projetar um algoritmo de clusterização de propósito geral e o problema de agrupamentos mal-configurados que podem ser enfrentados pela clusterização.

Basicamente o algoritmo *K-means*, em suas diversas formas, possui a seguinte

estrutura. Considera-se $\mathbf{X} = \{x_i, i = 1, \dots, n\}$ como o conjunto de n pontos dimensionais a serem clusterizados em um conjunto de K subconjuntos disjuntos (*clusters*) $\mathbf{C} = \{c_k, k = 1, \dots, K\}$. O algoritmo *K-means* localiza uma partição de tal forma que o erro quadrático entre a média empírica de um *cluster* e os pontos no *cluster* é minimizado, no qual μ_k é o centróide geométrico do *cluster* c_k . O erro quadrático entre μ_k e os pontos no cluster c_k é definido por:

$$J(c_k) = \sum_{x_i \in c_k} \|x_i - \mu_k\|^2. \quad (1)$$

O objetivo do *K-means* é minimizar a soma dos erros quadráticos de todos os *K clusters*, dado por:

$$J(C) = \sum_{k=1}^K J(c_k). \quad (2)$$

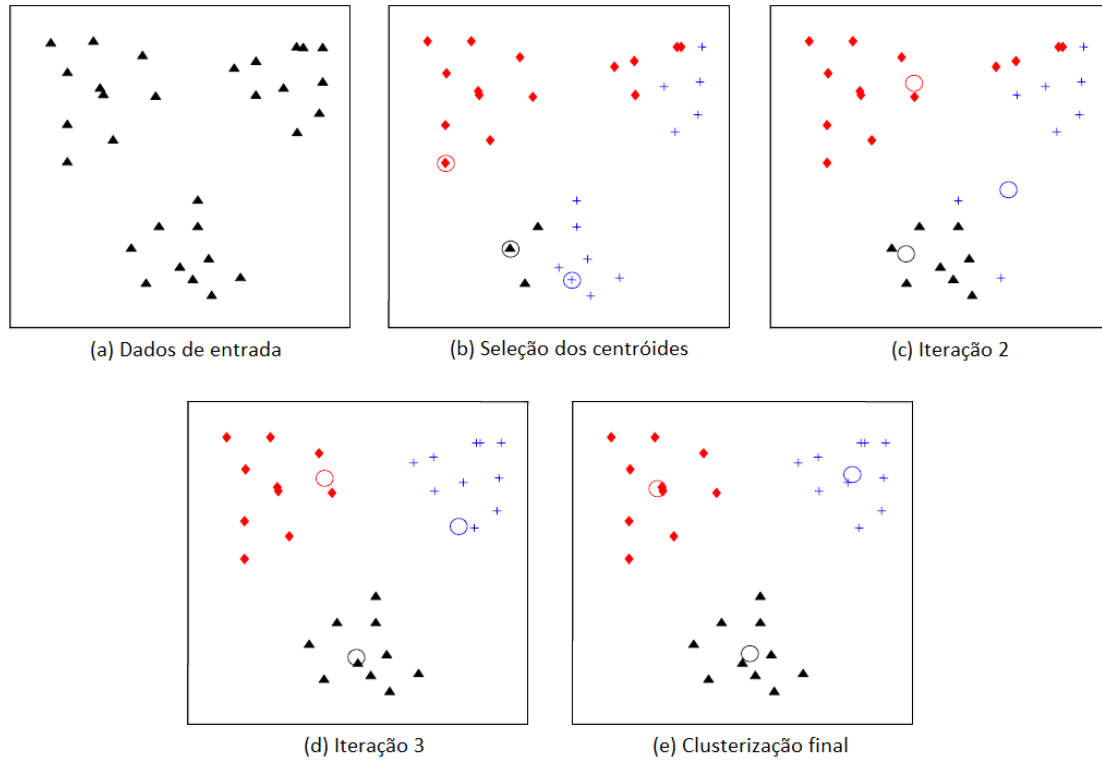
De acordo com Jain (2010), minimizar essa função objetivo é conhecido por ser um problema NP-completo. O *K-means* inicia com uma partição inicial com K *clusters* e busca atribuir padrões a *clusters* a fim de reduzir o erro quadrático. Como o erro quadrático sempre diminui com um aumento no número de *clusters* (com $J(C) = 0$ quando $K = n$), ele pode ser minimizado apenas para um número fixo de *clusters*. Os principais passos do algoritmo *K-means* são os seguintes:

1. Inicializar K centróides $\mu_1, \mu_2, \dots, \mu_k$ por valores iniciais conhecidos como *seed points*, geralmente utilizando inicialização aleatória;
2. Gerar uma nova partição atribuindo cada ponto ao centro do *cluster* mais próximo;
3. Recalcular o centróide μ_k de cada *cluster*;
4. Para todos os pontos x_i e todos K *clusters*, repetir os Passos 2 e 3 até todos os centróides convergirem.

A Figura 1 mostra uma ilustração do algoritmo *K-means* em um conjunto de dados bidimensional com três *clusters*. A Figura 1(a) representa os dados de entrada bidimensionais. Na Figura 1(b) foram definidos 3 centróides de forma aleatória e ocorreu a associação inicial dos pontos aos *clusters*. Iterações intermediárias são

representadas nas Figura 1(c) e (d), onde é atualizada a posição dos centróides e a designação dos pontos ao centróide mais próximo. A Figura 1(e) ilustra a clusterização final obtida pelo algoritmo *K-means* na convergência.

Figura 1: Exemplo de execução do algoritmo *K-means*



Fonte: Adaptado de (JAIN, 2010).

O *K-means* tem se mostrado eficaz na produção de bons resultados de clusterização em muitas aplicações práticas. Geralmente converge em poucas iterações para uma configuração estável, na qual nenhum elemento está designado para um *cluster* cujo centróide não seja o mais próximo. O número de *clusters* é considerado fixo no *K-means* originalmente proposto. A escolha apropriada do número de *K clusters* depende do problema e geralmente requer que o usuário faça uma análise de sensibilidade com diferentes valores de K (ZALIK, 2008).

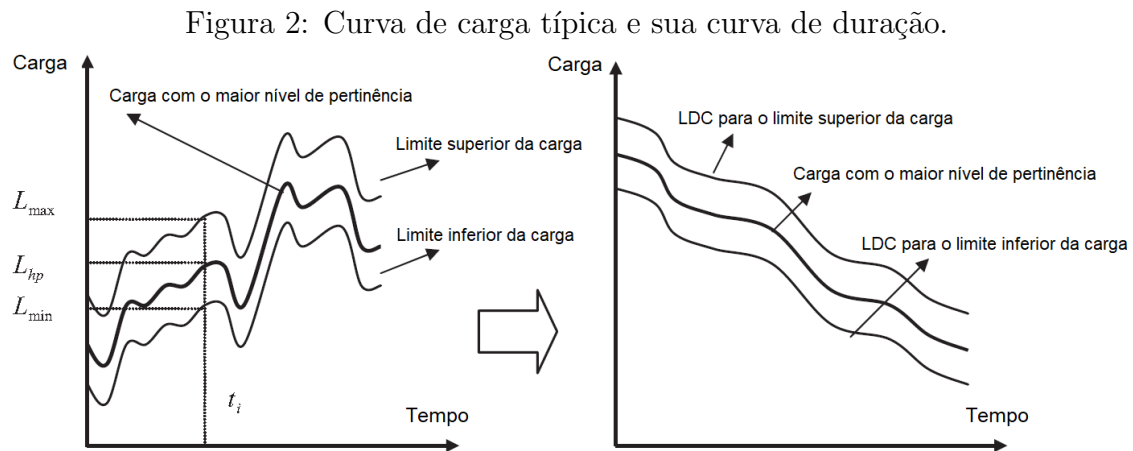
Desde o surgimento do algoritmo, inúmeros aprimoramentos e variações têm sido propostos. Zalik (2008) propõe uma adaptação ao algoritmo *K-means*, o qual executa a clusterização sem pré-atribuir o número exato de *clusters*. No trabalho de Likas, Vlassis e Verbeek (2003) são propostos os métodos *Global K-means* e *Fast Global K-means*, que não dependem da inicialização aleatória para os centro dos *clusters*, por empregar o algoritmo *K-means* como um procedimento de busca local.

Ao invés de selecionar aleatoriamente os valores iniciais para os centróides, a técnica proposta prossegue de maneira incremental, tentando otimizar o acréscimo de uma nova posição central de cada *cluster* a cada estágio.

2.2.3 Modelagem das incertezas

Nesta seção, é realizada uma breve revisão de algumas técnicas adotadas para a modelagem de incertezas na demanda de consumidores e em GDs, bem como as vantagens da consideração destas incertezas para a alocação ótima de BCs.

No que diz respeito a SDEE, alguns trabalhos como o de Haghifam e Malik (2007), Raju e Bijwe (2008), Mukherjee e Goswami (2014) e Zeinalzadeh, Mohammadi e Moradi (2015) propõem o uso de lógica *Fuzzy* para a representação da incerteza na carga. No trabalho de Haghifam e Malik (2007), a Figura 2 ilustra a representação por lógica *Fuzzy* de uma curva de carga típica e suas curvas de duração da carga (LDCs) com limites superiores e inferiores.




Fonte: Adaptado de Haghifam e Malik (2007).

Em qualquer instante de tempo, a carga pode ser representada como um número *Fuzzy*. Por exemplo, a carga no instante de tempo t_i da Figura 2 pode ser representada como um número triangular *Fuzzy*, o que é ilustrado pela Figura 3.

Na representação da carga por lógica *Fuzzy* da Figura 3, L_{min} é o limite inferior da carga, L_{max} é o limite superior da carga e L_{hp} é a carga com o maior nível de pertinência, ou seja, a carga com a maior probabilidade de ocorrência.

Li *et al.* (2018) utilizaram dois conjuntos de incertezas que atuam simultaneamente para representar as incertezas na carga e na GD. São construídas a HLRU

Figura 3: Carga em um horário típico (t_i) como um número triangular *Fuzzy*.



Fonte: Adaptado de Haghifam e Malik (2007).

(*Hourly net Load Ramping Uncertainty*), para caracterizar a variação da carga líquida horária incluindo a geração de energia eólica e a LDCU (*Load Duration Curve Uncertainty*), definida para representar a incerteza da curva de duração da carga líquida anual. Neste contexto, a HLRU é introduzida como uma compensação para descrever a variação horária da carga líquida, atenuando a diferença entre a curva de duração da carga anual e a curva da carga diária.

Os dois tipos de incerteza são acoplados entre si, aumentando a complexidade do problema. Na prática, 8760 horas de consumo de carga são ordenadas de forma decrescente para construir uma curva de duração da carga líquida anual, indicando que cada nível de carga líquida na curva de duração da carga anual corresponde a um nível de carga em uma hora específica em um determinado dia. Considerando uma hora específica, t , a LDCU representa a incerteza da carga líquida na hora t , enquanto a HLRU indica a variação da carga líquida da hora t para a hora $t + 1$.

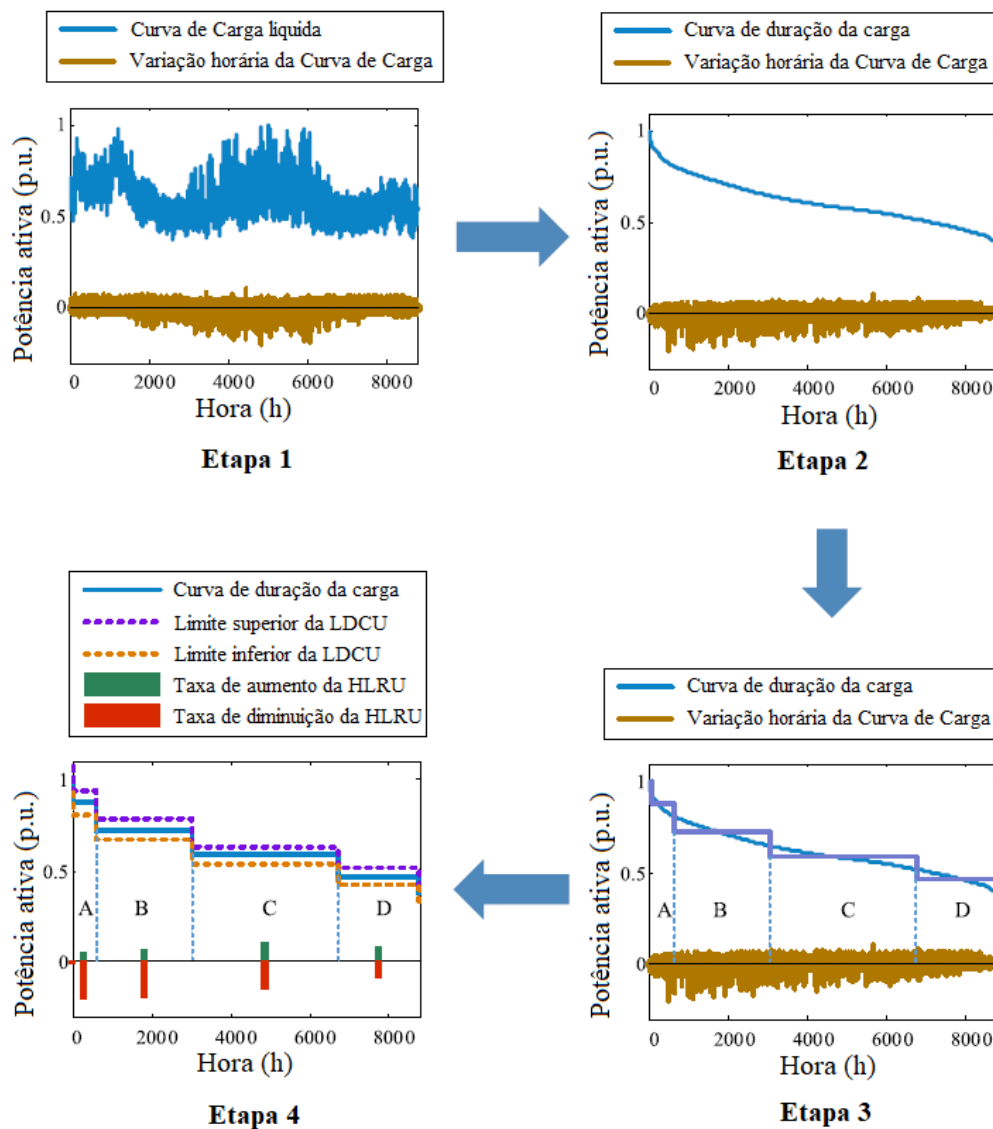
A Figura 4 ilustra o processo de construção dos conjuntos de incerteza LDCU e HLRU baseados em uma curva de carga anual.

As etapas de construção são as seguintes:

1. Contabilizar os eventos de variação de carga líquida a cada hora a partir de uma curva de carga anual;
2. Construir uma curva de duração da carga anual e organizar os eventos de variação de carga líquida horários correspondentes;
3. Linearizar a curva de duração da carga líquida anual. A curva é dividida em níveis de carregamento. Neste exemplo, são gerados 4 níveis (A, B, C e D);

4. Construir os conjuntos de incertezas. Com base na carga média de cada nível de carregamento, os limites superiores e inferiores do conjunto LDCU são construídos de acordo com o erro de previsão das curvas de carga. O intervalo de HLRU definido para cada nível é derivado dos eventos máximos de crescimento e diminuição da carga líquida em cada nível.

Figura 4: Processo de construção dos conjuntos LDCU e HLRU.

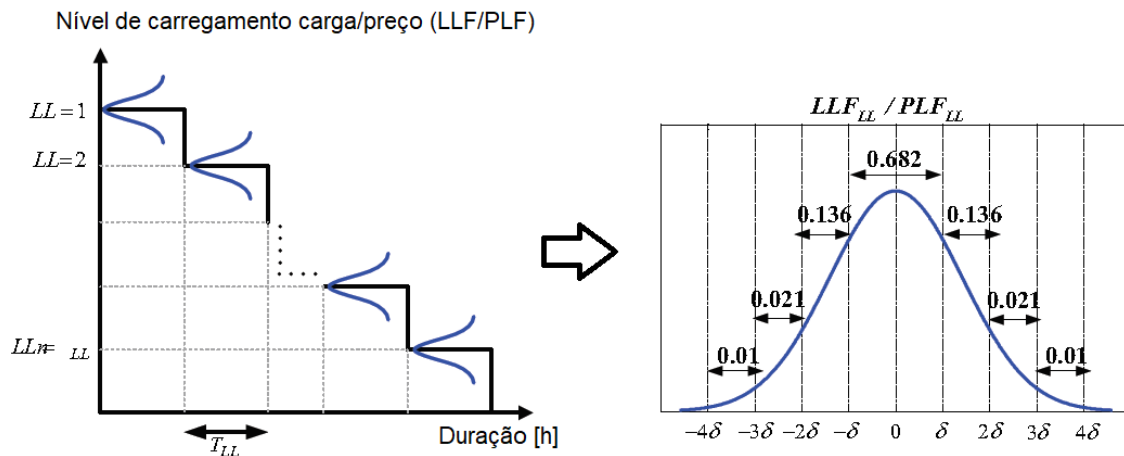


Fonte: Adaptado de Li *et al.* (2018).

Inúmeros trabalhos representam as incertezas associadas aos parâmetros dos sistemas elétricos de potência através de curvas PDF. Bagheri, Monsef e Lesani (2015) modelaram as incertezas relativas a carga e ao preço da energia através de curvas PDF, no qual foi utilizada uma curva de duração, segmentada em níveis de carre-

gamento, para considerar a variação da carga e do preço da energia durante o ano e calcular os custos operacionais com precisão, conforme ilustrado pela Figura 5. Nesta figura, o eixo vertical ilustra os níveis de carregamento da carga/preço (a razão entre a carga/preço para o valor de pico da carga/preço no ano de planejamento) e a duração de cada nível de carregamento (LL) é denotada por T_{LL} no eixo horizontal.

Figura 5: Curva de duração da carga/preço e o modelo de incerteza relacionado.



Fonte: Adaptado de Bagheri, Monsef e Lesani (2015).

A demanda de carga e o preço da energia são geralmente parâmetros com alto grau de incerteza nos problemas de planejamento da expansão de sistemas elétricos, sendo dependentes uns dos outros. Para modelar essas duas incertezas, Bagheri, Monsef e Lesani (2015) assumiram que os níveis de carga/preço seguem uma distribuição normal em torno de seus valores esperados, como mostrado pela Figura 5. Para simplificar, as curvas PDF são segmentadas em estados (sete estados na Figura 5) com as suas probabilidades relacionadas. Embora os valores esperados de preço e demanda sejam dependentes, em cada nível de demanda, a variação de preço da energia e da carga em torno de seu valor esperado pode ser considerada independente.

De acordo com Ravadanegh, Oskuee e Karimi (2017), o planejamento de sistemas elétricos de potência considerando incertezas é o desafio mais importante para os tomadores de decisão. O equilíbrio entre a geração e o consumo deve-se manter em tempo real e a rede elétrica deve ser capaz de transferir a energia necessária aos consumidores.

Em métodos determinísticos, os parâmetros do sistema, como consumo, geração e configuração da rede, são modelados como valores constantes. Em uma rede real, entretanto, esses parâmetros variáveis no tempo são de natureza aleatória. As incertezas referentes a estes parâmetros que variam aleatoriamente no sistema não podem ser analisadas por métodos determinísticos e, por essa razão, os métodos probabilísticos são mais adequados para essa finalidade (JANNAT; SAVIC, 2016).

2.2.4 Obtenção de cenários utilizando técnicas de clusterização

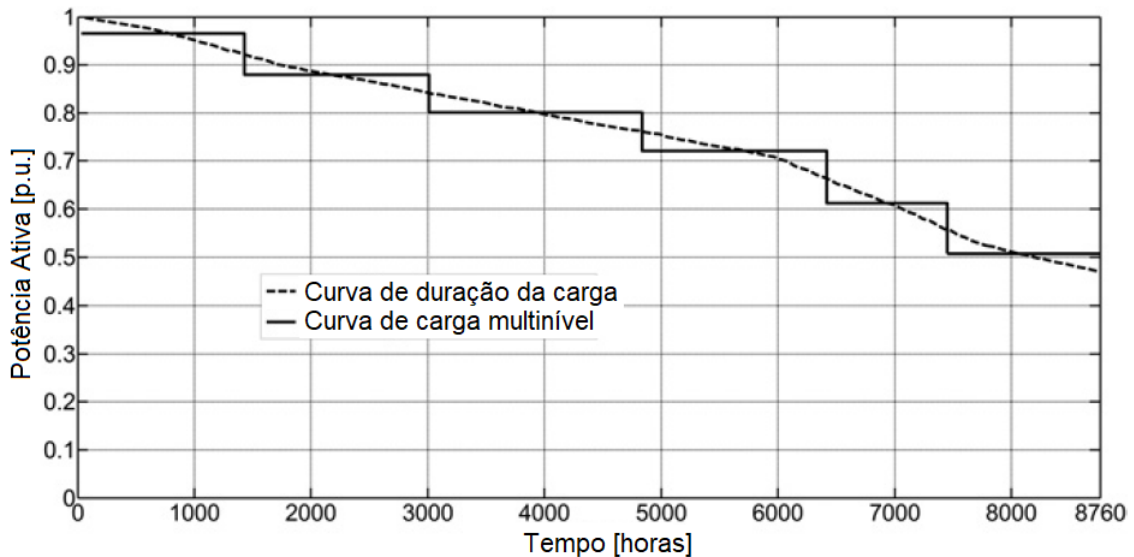
Nesta seção é apresentada uma revisão de métodos para a clusterização de dados utilizados para a geração de cenários representativos de curvas de carga e curvas de geração, com destaque para o algoritmo de clusterização *K-means*, método utilizado para a geração de cenários no presente trabalho.

Conforme Barbosa, Ricciardi e Freitas (2018), a obtenção de curvas de carga representativas para cada classe de consumidor é essencial para que as concessionárias de distribuição de energia elétrica tenham conhecimento sobre o comportamento do consumo de eletricidade de seus consumidores, pois tais informações podem ser utilizadas em estudos relacionados tanto a questões técnicas quanto a questões comerciais. A obtenção de um modelo matemático capaz de representar a realidade com 100% de precisão não é possível, porém o intuito é trabalhar com modelos adequados para cada situação. Estas curvas representativas auxiliam a tomadas de decisões tanto em áreas relacionadas ao planejamento quanto em áreas relacionadas à operação do sistema, com o objetivo de reduzir custos e melhorar a qualidade dos serviços prestados, através de melhores previsões de carga, planejamento da expansão do sistema, análises do mercado de energia elétrica, entre outros.

O consumo de energia elétrica é uma variável que exibe uma incerteza muito pronunciada. É uma função do tempo, condições climáticas, preços de mercado e muitos outros fatores. No trabalho de Jannat e Savic (2016), foram coletadas medições de consumo ao longo de um ano em um alimentador de distribuição. Os dados medidos foram convertidos para a curva de duração da carga e escalonados para a potência ativa máxima medida. Aplicando a clusterização *K-means*, a curva de duração da carga foi modelada por níveis de carregamento, segmentada em N níveis, o que corresponde a clusterização de pontos do consumo da carga em determinado

número de *clusters*, como representado pela Figura 6. A curva de duração da carga foi modelada por seis níveis de carregamento e após aplicada uma incerteza em torno de cada nível de carregamento, utilizando uma variável aleatória normalmente distribuída.

Figura 6: Curva de duração da carga e curva de múltiplos níveis de carregamento.



Fonte: Adaptado de Jannat e Savic (2016).

Uma forma para se obter curvas de demanda representativas é através do processo de clusterização, o qual realiza a classificação de dados formando grupos baseados em características similares. O conhecimento preciso dos padrões de consumo dos clientes representa um ativo valioso para os provedores de energia elétrica em mercados de eletricidade competitivos. Mahmoudi-Kohan, Mofhaddam e Bidoki (2009) compararam e avaliaram o desempenho dos algoritmos WFA (*Weighted Fuzzy Average*) *K-means* e *Modified Follow the Leader* na clusterização de curvas de carga. Na avaliação dos métodos foram considerados os indicadores MIA (*Mean Index Adequacy*), que representa a média das distâncias entre cada ponto atribuído ao *cluster* e seu centróide, e o CDI (*Clustering Dispersion Indicator*), que mescla as informações sobre a compactação dos *clusters* e inversamente sobre a distância entre eles. Foram realizadas simulações a partir de 127 curvas de carga comerciais e industriais de um sistema de distribuição real da cidade de Teerã.

Bidoki *et al.* (2010) deu continuidade ao trabalho e estendeu a avaliação considerando os algoritmos SOM (*Self-Organizing Maps*) e *K-means*. Em ambos trabalhos,

os algoritmos são executados para o número de *clusters* variável entre 2 e 15, a fim de obter o desempenho frente os indicadores MIA e CDI para o número variável de *clusters*. Os autores concluem que o algoritmo WFA *K-means*, por ter obtido os menores valores do indicador MIA, é útil para as aplicações que requerem uma maior diferença entre os *clusters*, como por exemplo, na definição de tarifas de eletricidade para grupos de consumidores com classes de consumo bem distintas. Já o algoritmo *Modified Follow the Leader*, por ter obtido menores valores do indicador CDI, é adequado para aplicações de clusterização com padrões mais semelhantes em cada grupo, o qual é indicado para políticas de resposta à demanda, por exemplo.

Barbosa, Ricciardi e Freitas (2018) utilizaram uma metodologia baseada na técnica de clusterização *Modified Follow the Leader* para obter curvas de carga representativas, nas quais as curvas são divididas em cinco patamares ordenados dentro das 24 horas de cada dia, conforme pode ser visto pela Tabela 2.

Tabela 2: Patamares para a representação das curvas de carga diárias.

Patamar	Horário (h)	
	Início	Término
Madrugada	00:00	06:00
Manhã	06:00	12:00
Tarde	12:00	18:00
Pico	18:00	21:00
Noite	21:00	24:00

Fonte: Adaptado de Barbosa, Ricciardi e Freitas (2018).

Com isso, o método é aplicado em cada patamar, de forma que para duas ou mais curvas serem agrupadas em um *cluster*, é necessário que elas pertençam aos mesmos conjuntos em todos os patamares. Após o processo ser realizado em todos os patamares, dentro de cada *cluster* é verificado quais curvas se encontram juntas em todos os patamares e com isso forma-se um *cluster* do conjunto. Para validar a metodologia, foram utilizadas medições fornecidas por uma concessionária, que contemplam consumidores de baixa e média tensão.

O trabalho de Assis *et al.* (2018) representa a intermitência associada à geração eólica por meio de cenários, obtidos pela técnica de clusterização *K-means*. Com isso, as séries históricas de capacidade de geração eólica são convertidas em cenários

com maior e menor probabilidade de ocorrência. Estes cenários são obtidos a partir de séries históricas de produção de energia de três regiões diferentes, entretanto, apenas são considerados cenários com patamares fixos de geração. A premissa foi adotada, segundo os autores, para reduzir o custo computacional no planejamento da expansão de sistemas de transmissão. Os autores afirmam também que a aplicação do método de clusterização apresenta a vantagem de capturar a correlação existente entre os potenciais eólicos de regiões diferentes.

No trabalho de Atwa e El-Saadany (2011), a metodologia baseia-se na geração de um modelo de carga-geração probabilístico, que combina todas as condições operacionais possíveis das GDs eólicas e os níveis de carga com suas probabilidades, com o intuito de realizar a alocação ótima de GDs e minimizar as perdas anuais de energia. A carga foi modelada a partir de uma técnica de clusterização desenvolvida por Singh e Kim (1988), a qual é segmentada em 10 níveis com diferentes probabilidades de ocorrência, o que segundo os autores, fornece um compromisso razoável entre precisão e uma rápida avaliação numérica. A Tabela 3 ilustra os estados propostos, na qual a coluna 1 apresenta os estados da carga, a coluna 2 o nível de carregamento e coluna 3 a probabilidade de ocorrência de cada estado.

Tabela 3: Estados da carga.

Estado da carga	Nível de carregamento (%)	Probabilidade
1	100	0,0100
2	85,3	0,0560
3	77,4	0,1057
4	71,3	0,1654
5	65,0	0,1654
6	58,5	0,1630
7	51,0	0,1630
8	45,1	0,0912
9	40,6	0,0473
10	35,1	0,0330

Fonte: Adaptado de Atwa e El-Saadany (2011).

Os estados de geração eólica foram modelados a partir da coleta de dados horários reais de velocidade do vento ao longo de um ano, segmentados pelo número de horas

de ocorrência de cada intervalo de velocidade do vento. Dessa forma, com a geração de curvas PDF de Rayleigh e a aplicação de clusterização, foram definidos 12 estados de geração eólica, ilustrados na Tabela 4.

Tabela 4: Estados de geração eólica

Estado de geração	Potência nominal (%)	Probabilidade
1	100	0,0784
2	94,97	0,0250
3	84,97	0,0326
4	74,98	0,0450
5	64,98	0,0501
6	54,98	0,0772
7	44,99	0,0912
8	34,99	0,1122
9	19,99	0,1036
10	15,00	0,1123
11	5,00	0,0660
12	0	0,2059

Fonte: Adaptado de Atwa e El-Saadany (2011).

Com isso, no trabalho de Atwa e El-Saadany (2011), o modelo de carga-geração é obtido listando todas as possíveis combinações entre os estados de geração e os estados de carga, totalizando 120 cenários com diferentes probabilidades de ocorrência. Na aplicação deste modelo probabilístico, a cada hora é sorteada uma combinação de carga-geração a fim de contabilizar as perdas anuais de energia e realizar a alocação ótima das GDs. Os autores afirmam que a representação probabilística gera bons resultados para o estudo de caso proposto, em um sistema de distribuição rural típico, frente ao modelo tradicional que considera valores médios de geração e de carga. Entretanto, os estados referentes à geração e à carga não são correlacionados, no qual os componentes diurnos e sazonais da velocidade do vento, bem como a carga, são negligenciados.

Bongers *et al.* (2016) apresentam também uma metodologia para a geração de cenários por meio de séries históricas de potencial eólico. Através de dados de geração de 8760 horas, é definido um cenário de maior chance de ocorrência com

limites superiores e inferiores no entorno da média. Primeiramente são geradas 1000 amostras de geração eólica por curvas PDF com a aplicação da Simulação Monte Carlo (SMC). Em uma segunda etapa, o algoritmo de clusterização *K-means* é utilizado para compactar o alto número de cenários de geração obtidos pela SMC, obtendo assim um limitado número de K cenários, que foi posteriormente definido em 10 cenários com geração fixa. No entanto, a partir de uma análise de sensibilidade nos resultados obtidos, os autores afirmam que 8 cenários são o suficiente para representar o planejamento de expansão do sistema proposto.

3 MODELO PROPOSTO PARA ALOCAÇÃO DE COMPENSAÇÃO DE POTÊNCIA REATIVA

Nesta seção, é descrito o modelo proposto para a alocação de BCs fixos e automáticos em sistemas de distribuição de energia elétrica (SDEE) considerando incertezas na carga e na GD. O modelo de expansão considera um estágio, com horizonte de operação de um ou mais anos. As incertezas na demanda e nas GDs são consideradas por intermédio de cenários de operação diária discretizados em 24 horas, o que possibilita a análise detalhada da operação dos BCs automáticos incluindo a definição do horário de funcionamento. Para os BCs automáticos, foi considerada a restrição de um chaveamento por dia. A rede, carga e GD foram representadas pelas equações de balanço de potência ativa e reativa do fluxo de carga (MONTICELLI, 1983).

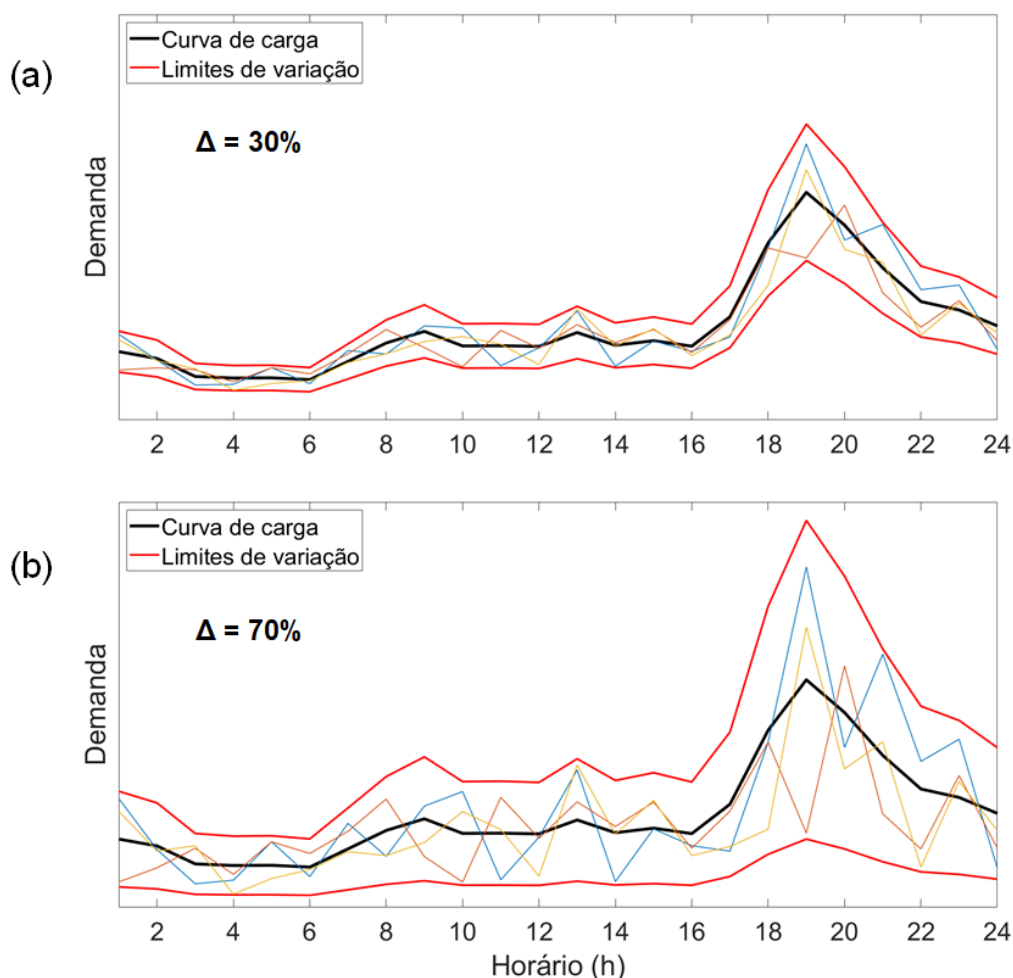
3.1 Avaliação da operação considerando cenários que descrevem a operação diária

Neste trabalho, com o intuito de permitir a obtenção de valores horários de demanda para todos os dias do ano com uma variância controlada, optou-se por gerar curvas de carga artificiais de maneira aleatória, a partir de curvas típicas de distintas classes de consumidores. Com isso, a incerteza intrínseca da demanda dos consumidores pode ser representada.

A Figura 7 ilustra a geração de curvas de carga artificiais a partir de uma curva de carga típica de consumidores residenciais para duas situações distintas. Cabe salientar que a geração das curvas artificiais aleatórias é realizada através da aplicação de distribuição uniforme, de modo a manter a variação dentro da faixa especificada.

Na Figura 7(a) é representada a geração de 3 curvas de carga para uma variação máxima de 30% sobre o valor da curva de carga típica e, na Figura 7(b), a geração de 3 curvas de cargas considerando uma variação máxima de 70%. As linhas em vermelho mais espessas delimitam os valores máximos e mínimos que as curvas de carga artificiais podem obter para o valor de Δ arbitrado.

Figura 7: Representação da geração de curvas de carga artificiais com variação máxima (Δ) de: (a) 30% e (b) 70%.



Fonte: Elaborada pelo autor.

A partir da Figura 7, pode-se perceber que as curvas de carga geradas têm comportamento bem distinto e com isso podem retratar de maneira mais realista as incertezas associadas ao comportamento da carga nos sistemas elétricos de potência. Pelo fato da variação empregada ser aplicada sobre cada instante de tempo, os horários com maior demanda apresentam uma maior variabilidade.

Na Seção 5.1.2 é detalhada a forma de obtenção das curvas de carga artificiais de

distintas classes de consumidores, bem como a aplicação destas em um sistema de 23 nós, no qual são testadas variações máximas entre 10 e 90%. Os testes avaliam a energia de perdas do sistema e as violações nos níveis de tensão para os diferentes casos simulados.

Muitas técnicas de clusterização têm sido propostas na literatura para obtenção de padrões para a representação da curva de carga de consumidores e gerações por fontes intermitentes, de acordo com as várias necessidades encontradas. No presente trabalho, o algoritmo de clusterização *K-means* foi adotado, principalmente devido a sua utilização consolidada e por ser um algoritmo simples e eficaz, conforme detalhado na Seção 2.2.2.

Na maior parte das referências consultadas, cenários de demanda de carga e GD demasiadamente simplificados são considerados e alguns trabalhos não consideram a utilização de curvas diárias, apenas estados de geração ou demanda fixos para representar um ano de operação. Essas abordagens simplificam muito a modelagem das incertezas, mas ignoram variações sazonais na demanda da carga e gerações de energia, além de desprezar a diversidade da carga entre os nós dos sistemas de distribuição. Portanto, uma representação mais detalhada é proposta neste trabalho, considerando-se curvas diárias de demanda e geração com resolução horária, o que busca representar os sistemas de distribuição da maneira mais realista possível, além de permitir avaliar de modo mais preciso a forma de operação de bancos de capacitores automáticos.

Na representação da demanda, o *K-means* é utilizado para obter curvas de cargas representativas e por consequência reduzir o vasto volume de informações gerado pela elaboração das curvas de carga artificiais para diferentes tipos de consumidores. Cada nó do sistema de distribuição é representando por K cenários representativos, de forma que para duas ou mais curvas de carga artificiais serem agrupadas em um mesmo cenário, elas devem pertencer aos mesmos conjuntos em todos os nós do sistema. Na Seção 5.1.2, são apresentados os resultados decorrentes da elaboração e análise destes cenários de curvas de carga representativas.

Os cenários representativos de GDs são obtidos a partir de curvas de geração de sistemas fotovoltaicos. É realizada a coleta de séries históricas de irradiação e temperatura nos módulos e a definição dos parâmetros dos sistemas fotovoltaicos

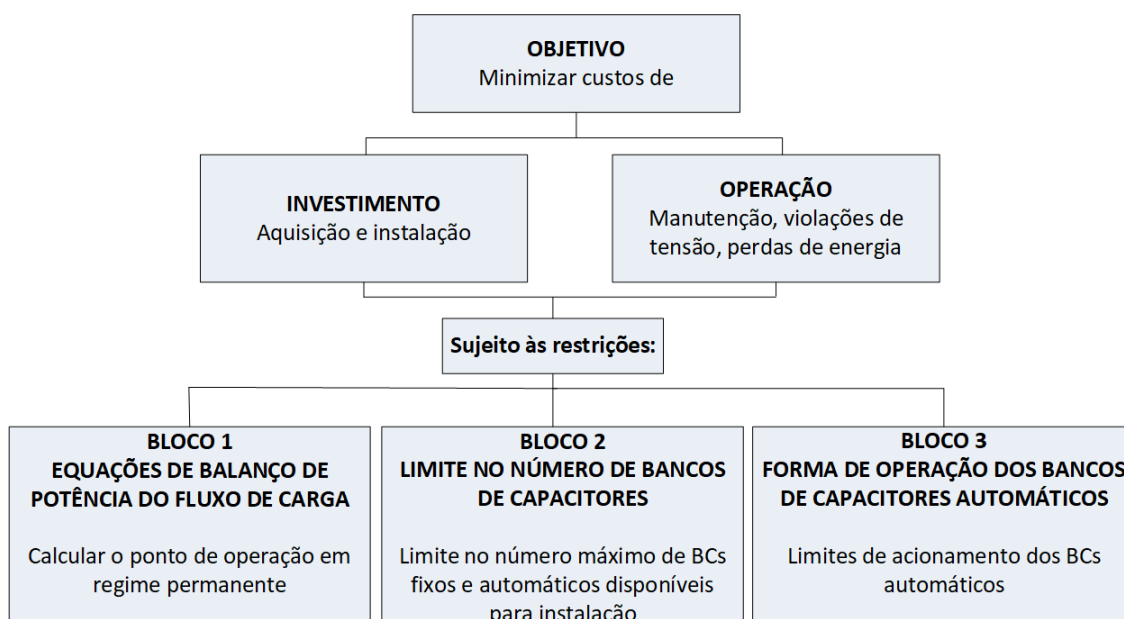
para a obtenção das curvas de geração. Os \mathcal{K} cenários representam curvas diárias com resolução horária para representar o histórico de geração fotovoltaica de maneira fidedigna com o menor número de cenários possível. A definição destes cenários é apresentada na Seção 5.1.3, na qual é realizada a validação dos mesmos e a aplicação das GDs em nós do sistema de distribuição.

3.2 Formulação do modelo empregado

A análise das alternativas de investimento é parte fundamental da atividade de planejamento de SDEE. Os custos envolvidos podem ser divididos em custos iniciais e custos recorrentes (por vezes chamados de custos anuais). Dentre os custos iniciais estão os investimentos na execução de um projeto; estes custos, uma vez pagos, não se repetem. Os custos recorrentes referem-se aos custos que são pagos periodicamente, tais como custos de operação e manutenção (RESENER, 2016). No modelo proposto, é utilizado o cálculo do valor presente líquido para avaliar os custos que ocorrem em diferentes instantes de tempo (custos iniciais e recorrentes), o que permite avaliar e comparar custos de forma consistente e com uma base comum.

Um diagrama ilustrativo do modelo de otimização proposto é apresentado na Figura 8.

Figura 8: Diagrama ilustrativo do modelo de otimização proposto.



Fonte: Elaborada pelo autor.

3.2.1 Função objetivo

A função objetivo do modelo proposto para a alocação de compensação de potência reativa é composta por duas parcelas, uma delas relacionada ao custo de investimento e outra relacionada ao custo de operação do sistema. O custo de investimento compreende os custos de aquisição e instalação dos BCs. Para possibilitar a obtenção dos fatores e calcular o valor presente, é considerado que o investimento é realizado uma única vez, no início do horizonte de planejamento. Por outro lado, o custo de operação é considerado no início de cada ano e corresponde ao custo anual de manutenção dos BCs, somado aos custos das perdas de energia e das penalidades aplicadas às violações dos limites adequados de tensão.

A Figura 9 mostra os instantes de efetivação dos custos de operação e investimento para um horizonte de planejamento de T anos, considerando \mathcal{K} cenários de operação. Conforme a Figura 9, os custos de investimento dos BCs ($C^{\text{inv}}(\mathbf{x})$) são pagos no início do horizonte de planejamento. Os custos de operação incluem os custos de manutenção ($C^m(\mathbf{x})$) dos BCs e os custos referentes a violação nos níveis de tensão ($C_K^v(\mathbf{w}_K)$) e das perdas de energia ($C_K^p(\mathbf{p}_K)$), valores descontados no início de cada ano, para cada cenário de operação.

A função objetivo é definida pela seguinte expressão:

$$C^{\text{total}}(\mathbf{x}, \mathbf{w}, \mathbf{p}) = C^{\text{inv}}(\mathbf{x}) + C^{\text{oper}}(\mathbf{x}, \mathbf{w}, \mathbf{p}) \quad (3)$$

onde:

C^{inv} – custo de investimento [\$];

C^{oper} – custo de operação [\$];

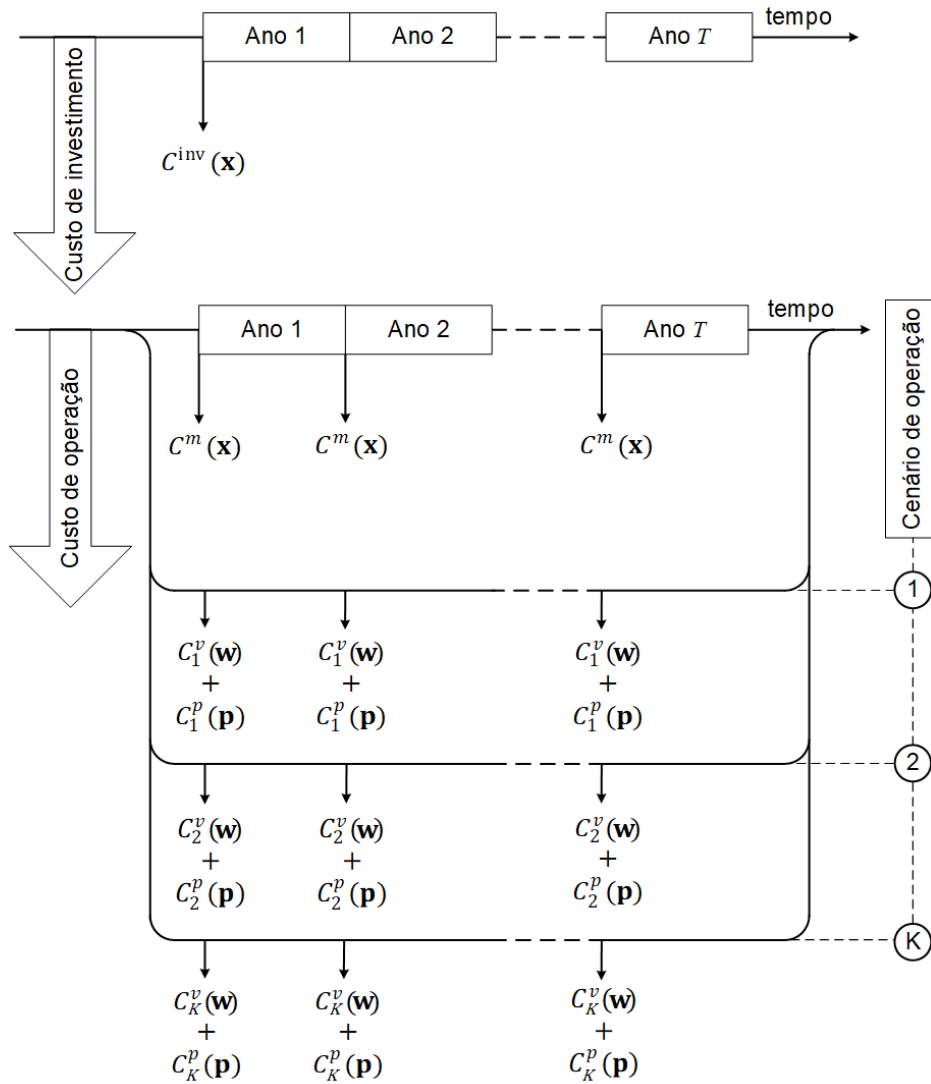
\mathbf{x} – vetor das variáveis de investimento;

\mathbf{w} – vetor das violações de tensão nos nós [pu];

\mathbf{p} – vetor das perdas ativas [kW].

O modelo de otimização proposto para o problema da alocação ótima de BCs considera a possibilidade de instalação de BCs fixos e automáticos. A variação da carga horária é levada em consideração na definição da melhor estratégia de operação dos BCs automáticos, ao considerar cenários representativos baseados em curvas de carga com resolução horária.

Figura 9: Instantes de efetivação dos custos de investimento e de operação.



Fonte: Adaptado de Haffner *et al.* (2009).

O investimento total é calculado pela soma dos custos de aquisição e instalação dos BCs. A seguinte expressão é utilizada para o cálculo do investimento:

$$C^{inv}(\mathbf{x}) = \sum_{m \in \Psi^{BC}} \left\{ \sum_{I \in \Psi^F} (CA^{FI} + CI_m^{FI})x_m^{FI} + \sum_{I \in \Psi^A} (CA^{AI} + CI_m^{AI})x_m^{AI} \right\} \quad (4)$$

onde as variáveis representam:

CA^{FI} – custo de aquisição do BC fixo tipo I [\\$];

CI_m^{FI} – custo de instalação do BC fixo tipo I no nó m [\\$];

CA^{AI} – custo de aquisição do BC automático tipo I [\\$];

CI_m^{AI} – custo de instalação do BC automático tipo I no nó m [\\$];

- x_m^{FI} – variável binária que indica a instalação de um BC fixo do tipo I no nó m ;
- x_m^{AI} – variável binária que indica a instalação de um BC automático do tipo I no nó m ;
- Ψ^{BC} – conjunto de nós candidatos a instalação de BCs;
- Ψ^F – conjunto dos BCs fixos que podem ser instalados;
- Ψ^A – conjunto dos BCs automáticos que podem ser instalados.

O custo total de operação é dado pela soma dos custos de manutenção, das violações dos limites de tensão e das perdas, definido nas equações (5) e (6):

$$C^{\text{oper}}(\mathbf{x}, \mathbf{w}, \mathbf{p}) = \delta(T, i\%) \left\{ C^m(\mathbf{x}) + \sum_{K=1}^{\kappa} \Delta t_K [C_K^v(\mathbf{w}_K) + C_K^p(\mathbf{p}_K)] \right\} \quad (5)$$

$$\delta(T, i\%) = \sum_{t=1}^T \frac{1}{\left(1 + \frac{i\%}{100}\right)^{t-1}} \quad (6)$$

onde:

- C^m – custo anual de manutenção [\$/ano];
- C_K^v – custo diário das violações dos limites de tensão no cenário K [\$/dia];
- C_K^p – custo diário das perdas de energia no cenário K [\$/dia];
- κ – número total de cenários de operação;
- δ – fator de conversão para cálculo do valor presente;
- T – horizonte de planejamento [anos];
- $i\%$ – taxa de juros anual [%];
- Δt_K – duração anual do cenário K [dias/ano];
- \mathbf{w}_K – vetor das violações de tensão nos nós no cenário K [pu];
- \mathbf{p}_K – vetor das perdas ativas no cenário K [kWh].

Os custos anuais de manutenção dos BCs são definidos pela seguinte expressão:

$$C^m(\mathbf{x}) = \sum_{m \in \Psi^{BC}} \left\{ \sum_{I \in \Psi^F} C M^{FI} x_m^{FI} + \sum_{I \in \Psi^A} C M^{AI} x_m^{AI} \right\} \quad (7)$$

onde:

CM^{FI} – custo anual de manutenção do BC fixo tipo I [\$/ano];

CM^{AI} – custo anual de manutenção do BC automático tipo I [\$/ano].

O custo das violações dos limites de tensão é obtido através de um fator de penalização que considera os indicadores de conformidade no nível de tensão em regime permanente, regulamentados pela Agência Nacional de Energia Elétrica (ANEEL), conforme o Módulo 8 dos Procedimentos de Distribuição de Energia Elétrica no Sistema Elétrico Nacional (ANEEL, 2018), adaptados para cenários de operação com resolução horária conforme a metodologia proposta. O custo diário das violações nos limites de tensão, como uma compensação média para um ano de operação, é definido como:

$$C_K^v(\mathbf{w}_K) = \left[\left(\frac{DRP_{\text{dia}}(\mathbf{w}_K) - DRP_{\text{limite}}}{100} \right) k_1 + \left(\frac{DRC_{\text{dia}}(\mathbf{w}_K) - DRC_{\text{limite}}}{100} \right) k_2 \right] \text{EUSD} \quad (8)$$

$$DRP_{\text{dia}} = \frac{nlp}{24} \times 100 \quad (9)$$

$$DRC_{\text{dia}} = \frac{nlc}{24} \times 100 \quad (10)$$

onde:

DRP_{dia} – duração relativa da transgressão de tensão precária diária [%];

DRP_{limite} – duração relativa da transgressão de tensão precária diária limite [%];

DRC_{dia} – duração relativa da transgressão de tensão crítica diária [%];

DRC_{limite} – duração relativa da transgressão de tensão crítica diária limite [%];

k_1 – variável que assume $k_1 = 0$ se $DRP_{\text{dia}} \leq DRP_{\text{limite}}$ ou $k_1 = 3$ se

$$DRP_{\text{dia}} > DRP_{\text{limite}} ;$$

k_2 – variável que assume $k_2 = 0$ se $DRC_{\text{dia}} \leq DRC_{\text{limite}}$ ou caso

$DRC_{\text{dia}} > DRC_{\text{limite}}$, assume $k_2 = 7$ para consumidores atendidos em

baixa tensão, $k_2 = 5$ para consumidores atendidos em média tensão ou

$k_2 = 5$ para consumidores atendidos em alta tensão;

$EUSD$ – encargo do uso do sistema de distribuição [\$/dia];

nlp – número de leituras diárias situadas nas faixas precárias;

nlc – número de leituras diárias situadas nas faixas críticas.

Por fim, o custo decorrente das perdas de energia é definido através da seguinte expressão:

$$C_K^p(\mathbf{p}_K) = C^{kWh} \sum_{h=1}^{24} \left(p_K^{\text{perdas}} \right)_h \quad (11)$$

onde:

C^{kWh} – custo da energia [\$/kWh];

$\left(p_K^{\text{perdas}} \right)_h$ – perdas ativas do sistema durante o cenário K para a hora h [kWh/dia].

3.2.2 Restrições

As restrições do problema de alocação de BCs consideram a aplicação das equações de balanço do fluxo de carga convencional, o limite no número de BCs para todos cenários e os limites na forma de operação dos BCs automáticos. Pode-se dividi-las em três blocos, sendo o primeiro bloco obtido a partir das equações de balanço do fluxo de carga convencional (não-linear), definidas para cada hora e para cada cenário, conforme as seguintes expressões (MONTICELLI, 1983):

$$P_{h,K}^{\text{calc}}(\mathbf{x}, \mathbf{y}_h) = P_{h,K}^{\text{esp}}, \quad \forall h = 1, 2, \dots, 24, \quad \forall K = 1, 2, \dots, \kappa \quad (12)$$

$$Q_{h,K}^{\text{calc}}(\mathbf{x}, \mathbf{y}_h) = Q_{h,K}^{\text{esp}}, \quad \forall h = 1, 2, \dots, 24, \quad \forall K = 1, 2, \dots, \kappa \quad (13)$$

onde:

$P_{h,K}^{\text{calc}}, Q_{h,K}^{\text{calc}}$ – injeções de potência ativa e reativa calculadas no horário h para o cenário K ;

$P_{h,K}^{\text{esp}}, Q_{h,K}^{\text{esp}}$ – injeções de potência ativa e reativa especificadas no horário h para o cenário K ;

\mathbf{y}_h – vetor com as variáveis binárias que representa o modo de operação dos BCs automáticos para o horário h .

O segundo bloco de restrições é formado pelo limite no número máximo de BCs que podem ser instalados. Cada tipo de banco possui uma quantidade máxima de equipamentos disponíveis para instalação, conforme as restrições:

$$\sum_{m \in \Psi^{BC}} x_m^{FI} \leq NB_{\max}^{FI}, \quad \forall I \in \Psi^F \quad (14)$$

$$\sum_{m \in \Psi^{BC}} x_m^{AI} \leq NB_{\max}^{AI}, \quad \forall I \in \Psi^A \quad (15)$$

onde NB_{\max}^{FI} e NB_{\max}^{AI} representam o número disponível de BCs fixos do tipo I e automáticos do tipo I , respectivamente. A quantidade máxima de bancos fixos e automáticos é limitada pela seguinte restrição:

$$\sum_{m \in \Psi^{BC}} \left(\sum_{I \in \Psi^F} x_m^{FI} + \sum_{I \in \Psi^A} x_m^{AI} \right) \leq NB_{\max} \quad (16)$$

onde NB_{\max} representa o número máximo de BCs dos tipos fixo e/ou automático que podem ser instalados.

O terceiro bloco de restrições refere-se aos limites empregados à forma de operação dos BCs. Os BCs automáticos só podem ser ligados uma vez ao dia, o que limita o número máximo de transições para dois acionamentos (liga/desliga). Cada dia de operação (K cenário) é independente. Portanto, a quantidade máxima de transições dos BCs automáticos é limitada pela seguinte restrição:

$$\sum_{h=1}^{23} |y_{h+1,K,m} - y_{h,K,m}| \leq 2, \quad \forall K = 1, 2, \dots, \kappa \quad \forall m \in \Psi^{BC} \quad (17)$$

onde $y_{h,K,m}$ é uma variável binária que representa o modo de operação do BC automático para o horário h , no cenário K e no nó m . $y_{h,K,m} = 1$ significa que a unidade automática do nó m está ligada no horário h para o cenário K ; caso contrário, $y_{h,K,m} = 0$.

3.2.3 Indicador de violação nos níveis de tensão


A fim de realizar comparações entre os resultados obtidos pelo modelo proposto e de forma similar na comparação dos cenários representativos obtidos, é definido um indicador adicional para o cálculo das violações dos níveis de tensão. Na formulação adotada, o desvio da tensão nodal com relação aos seus limites mínimo e máximo é definido para todos os nós com carga ($\forall m \in \Psi^D$) e todos os cenários de operação ($\forall K \in \Psi^\kappa$), conforme as seguintes expressões:

$$z_{m,K} = \frac{1}{24} \sum_{h=1}^{24} z_{h,m,K} \quad (18)$$

$$z_{h,m,K} = \begin{cases} V_{h,m,K} - V_m^{\max}, & \text{se } V_{h,m,K} > V_m^{\max} \\ V_m^{\min} - V_{h,m,K}, & \text{se } V_{h,m,K} < V_m^{\min} \\ 0, & \text{caso contrário.} \end{cases} \quad (19)$$

onde $z_{h,m,K}$ representa a violação de tensão no nó m no horário h no cenário de operação K , V_m^{\min} e V_m^{\max} representam os limites de tensão (mínimo e máximo) no nó m , e $V_{h,m,K}$ a tensão na hora h e no nó m durante o cenário K , todos representados em valores por unidade. A expressão linear por partes da equação (19) corresponde aos segmentos de reta da Figura 10.

Figura 10: Função de representação da violação dos limites de tensão.



Fonte: Adaptado de Haffner *et al.* (2009).

O somatório das violações de tensão para um ano de operação pode então ser obtido pelas seguintes expressões:

$$Z = \sum_{K=1}^{\kappa} \Delta t_K z_K \quad (20)$$

$$z_K = \sum_{m \in \Psi^D} z_{m,K} \quad (21)$$

onde z_K representa o somatório das violações de tensão durante o cenário K e Z representa o somatório das violações de tensão para um ano de operação, ambos em pu.

4 ALGORITMO GENÉTICO PARA A ALOCAÇÃO DE COMPENSAÇÃO DE POTÊNCIA REATIVA

O AG é uma ferramenta de otimização baseada no princípio da seleção natural e na genética. Os AGs são algoritmos de busca nos quais a busca é conduzida utilizando informações da população de soluções candidatas para que a chance de a busca ficar presa em uma solução local possa ser significativamente reduzida, facilitando a convergência para uma solução ótima global (RAJU; BIJWE, 2008).

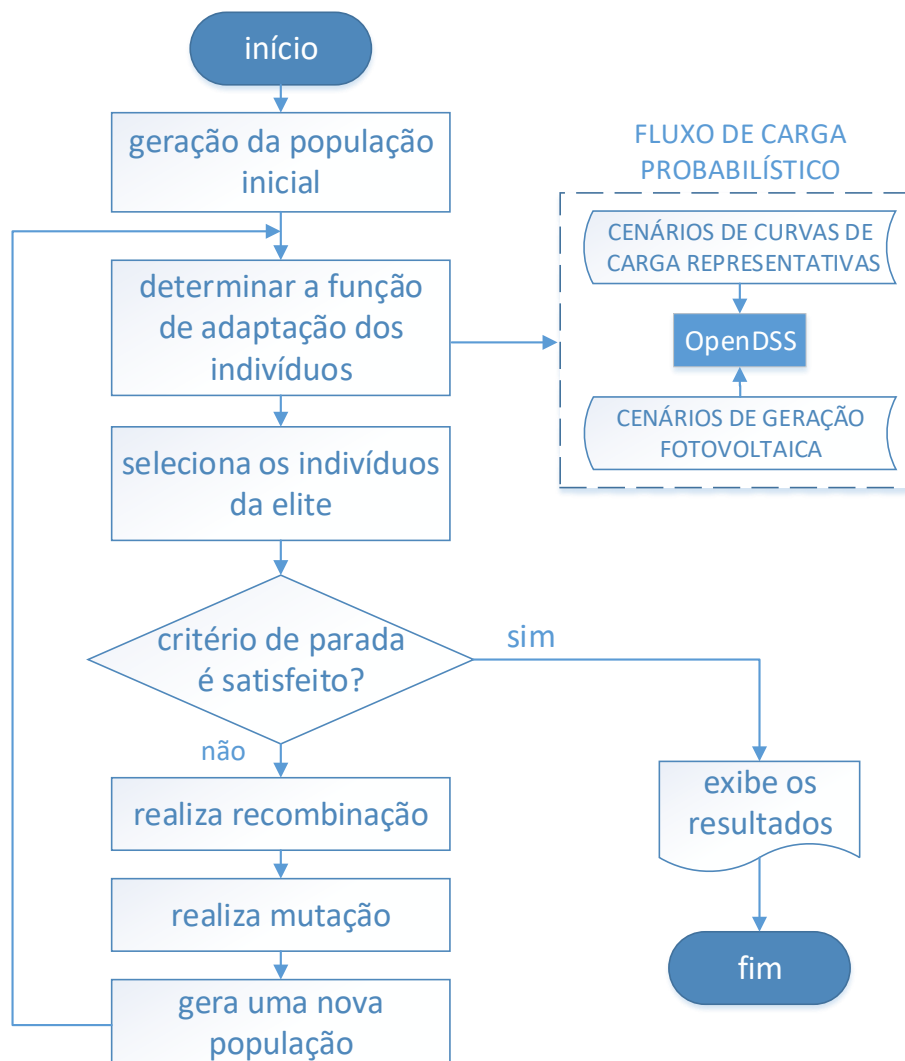
As principais vantagens do AG quando comparadas aos métodos clássicos de otimização são a possibilidade de representar qualquer tipo de função objetivo e restrições, independentemente de serem contínuas, discretas, lineares ou não-lineares, e a capacidade de lidar com problemas complexos com um espaço de busca muito grande. Por outro lado, o AG exige um esforço computacional considerável e não garante a obtenção da solução ótima. Esses recursos, no entanto, não impedem a aplicação do AG em problemas de planejamento, uma vez que o objetivo é obter uma boa alternativa de expansão e não apenas o ótimo global, com menor preocupação sobre a eficiência computacional (BORGES; MARTINS, 2012).

Neste trabalho, a solução para o problema de otimização é obtida através de um AG especializado que tem as seguintes características:

- codificação inteira;
- seleção por torneio;
- três mecanismos de recombinação;
- elitismo;
- controle explícito de diversidade da população;
- busca local em torno de um dos indivíduos da elite a cada geração.

O algoritmo de otimização consiste nas etapas descritas a seguir. Elas são baseadas nos conceitos clássicos de AGs. No entanto, mudanças importantes nas operações básicas foram implementadas para tornar o algoritmo mais eficiente quando aplicado ao modelo de otimização proposto neste trabalho. A estrutura geral do algoritmo implementado é ilustrada pelo fluxograma da Figura 11.

Figura 11: Fluxograma do AG.



Fonte: Elaborada pelo autor.

1. *Início*. São definidos os parâmetros básicos de controle: o número de indivíduos na população e na elite (n_{pop} e n_{eli} , respectivamente); o número máximo de gerações ($n_{\text{ger}}^{\text{max}}$); as taxas de recombinação e mutação (t_{rec} e t_{mut} , respectivamente); a distância mínima entre os indivíduos da população inicial ($d_{\text{init}}^{\text{min}}$); a

distância mínima entre os indivíduos da população ($d_{\text{pop}}^{\text{min}}$); a distância mínima entre os indivíduos da elite ($d_{\text{eli}}^{\text{min}}$); e o contador de iterações ($n_{\text{ger}} = 0$).

2. *Geração da população inicial:* $5n_{\text{pop}}$ indivíduos são gerados aleatoriamente, resultando em um conjunto de n_{pop} indivíduos com características distintas.
3. *Repetir as etapas a seguir:*
 - (a) determinar a adaptação de cada indivíduo e ordenar a população;
 - (b) selecionar os n_{eli} melhores indivíduos com características diferentes (distância maior que $d_{\text{eli}}^{\text{min}}$) visando compor o grupo da elite;
 - realizar uma busca local em torno de um dos indivíduos da elite.
 - (c) critério de parada: se $n_{\text{ger}} > n_{\text{ger}}^{\text{max}}$ vá para o Passo 4; caso contrário, prosseguir;
 - (d) realizar a recombinação, de acordo com a probabilidade definida por t_{rec} ;
 - (e) realizar a mutação, de acordo com a probabilidade definida por t_{mut} ;
 - (f) gerar uma nova população incluindo apenas indivíduos que possuam características diferentes (ou seja, com distância maior que $d_{\text{pop}}^{\text{min}}$);
 - (g) atualizar o contador de gerações ($n_{\text{ger}} = n_{\text{ger}} + 1$).
4. *Exibe os resultados.* Gera um relatório com as soluções obtidas;
5. *Fim.*

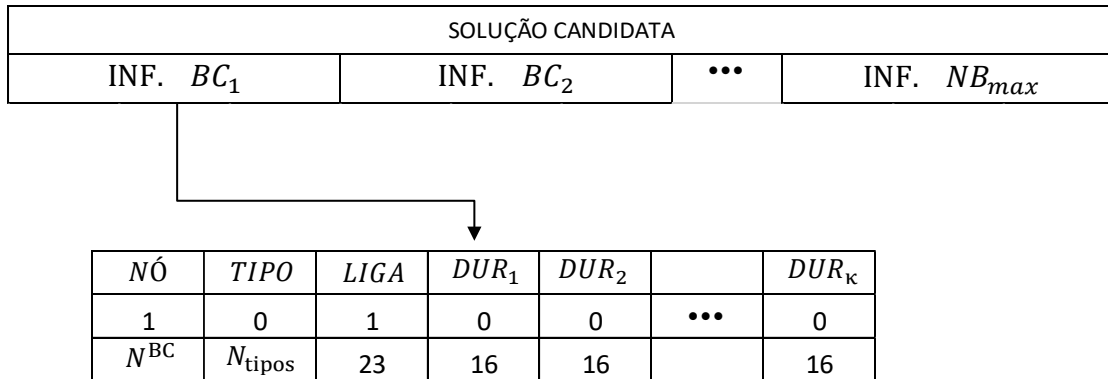
4.1 Codificação empregada

Os processos de representação e codificação são fundamentais para o sucesso de qualquer problema que venha a ser resolvido por intermédio de AGs. Gerar de forma totalmente aleatória configurações, apesar de propiciar o aspecto da diversidade da população, pode originar configurações ineficazes, além de impor um esforço computacional excessivo e gerar propostas de investimento pouco atraentes.

Na representação proposta para o modelo de alocação ótima de BCs, cada cromossomo representa uma solução candidata, composta por um conjunto de genes que caracteriza a codificação. O cromossomo contém as seguintes informações: (i) nó do sistema onde vai ser alocado o BC, (ii) tipo de BC (potência instalada e modo de funcionamento), (iii) horário que liga e (iv) duração da operação de cada um

dos K cenários; replicados para o número máximo de BCs definido (NB_{max}). A codificação empregada para a representação de uma solução candidata é ilustrada pela Figura 12, na qual são apresentados também os limites inferior e superior para o valor que cada gene do cromossomo pode assumir.

Figura 12: Codificação empregada para o modelo de alocação ótima de BCs.



Fonte: Elaborada pelo autor.

Conforme a Figura 12, o tamanho do cromossomo é variável, visto que o número de genes depende da definição de alguns parâmetros: número máximo de BCs e o número de K cenários representativos da operação do sistema.

Os alelos que podem ser atribuídos a cada um dos genes dependem do que cada gene está representando. O primeiro gene associado a cada um dos NB_{max} BCs representa o nó no qual o BC selecionado será instalado, podendo assumir valores entre 1 e N^{BC} , que é a cardinalidade do conjunto Ψ^{BC} . O segundo gene representa o tipo de BC que será instalado, podendo assumir valores entre 0 (nenhum BC instalado) e N_{tipos} , que é a soma da cardinalidade dos conjuntos Ψ^F e Ψ^A .

Os genes a seguir contém a informação do horário que os BCs automáticos serão ligados (horário fixo para todos os K cenários de operação¹), bem como as durações que cada BC automático deverá ficar ligado para os K cenários. O horário que o BC será ligado varia entre 1h e 23h²; a duração de cada K cenário varia entre 0h

¹para simplificar a definição do modo de operação dos BCs automáticos, foi definido um horário único de acionamento para todos cenários. Havendo necessidade, a codificação pode ser estendida para incluir horários diferenciados para cada cenário, mas isto acarreta um aumento significativo no espaço de busca do problema.


²Para um mínimo de 1h de operação estas são todas as opções possíveis.

(não liga) e 16h³. Desta forma, são utilizados K genes para representar a duração em cada um dos K cenários.

Caso o BC a ser instalado seja do tipo fixo ou do tipo 0 (sem BC), os genes relativos ao horário que liga e as durações não são considerados.

Como forma de exemplificar a codificação proposta, a Figura 13 ilustra uma solução candidata do modelo de alocação de BCs. São considerados os seguintes parâmetros: 2 BCs disponíveis para alocação (BC_1 e BC_2), um sistema composto por 22 nós candidatos ($N^{BC} = 22$), 5 tipos disponíveis de BCs ($N_{\text{tipos}} = 5$) e 3 cenários representativos da operação do sistema ($\mathcal{K} = 3$).

Figura 13: Exemplo de uma solução candidata.



Fonte: Elaborada pelo autor.

Na Figura 13, os dois primeiros genes do BC_1 representam a alocação de um BC no nó 18 do sistema, do tipo 3. Caso o tipo 3 represente um BC automático, este ligará às 13h, conforme ilustrado pelo terceiro gene. Os genes 4 a 6 ilustram a duração da operação de cada um dos 3 cenários, nos quais a DUR_1 é de 10h, a DUR_2 é de 0h (não liga) e a DUR_3 é de 5h. Desta forma, caso o BC_1 seja automático, irá operar das 13h às 23h para o Cenário 1, no Cenário 2 permanece desligado e no Cenário 3 irá operar das 13h às 18h. De forma análoga, o BC_2 é alocado no nó 15 do sistema, sendo um BC do tipo 2. Este BC, caso seja automático, ligará às 17h e terá as durações de operação de 2h, 9h e 5h para os cenários de operação 1, 2 e 3, respectivamente.

O emprego da duração para cada cenário é conveniente, pois evita o surgimento de soluções infactíveis associadas a operação dos BCs automáticos. Estes valores são convertidos para o horário de desligamento do BC ao avaliar a função de adaptação, limitados ao valor de 24h⁴, pois cada cenário opera de maneira independente.

³Neste caso, foi feita uma redução nas possibilidades, pois não parece atrativo utilizar um BC automático que opera quase a totalidade do dia.

⁴Caso o somatório do horário em que o BC liga e a duração de sua operação seja maior que 24h, é atribuído o horário de desligamento limite (24h). Por outro lado, caso a duração seja 0, o BC não será ligado neste cenário.

Devido ao fato do cromossomo ter tamanho variável, o espaço de busca do problema varia consideravelmente para cada conjunto de parâmetros definidos: número máximo de BCs, número de nós candidatos a instalação de BCs do sistema, número de tipos de BCs, número de K cenários utilizados para representar o horizonte de operação. Além disso, é importante observar que a quantidade de informações consideradas nos BCs fixos é diferente da considerada nos BCs automáticos. Para BCs fixos, somente são considerados o nó de instalação e o tipo de BC; para BCs automáticos, considera-se adicionalmente o horário de acionamento e as durações de cada cenário.

Caso sejam considerados apenas BCs fixos, o espaço de busca do modelo de otimização, empregando a codificação descrita, é dado pela seguinte expressão:

$$EB_{\text{fixo}} = [N^{\text{BC}} \times (N^{\text{F}} + 1)]^{NB_{\text{max}}} \quad (22)$$

sendo N^{F} a cardinalidade do conjunto de BCs fixos.

Por outro lado, caso sejam considerados apenas BCs automáticos, o espaço de busca do modelo de otimização, empregando a codificação descrita, é dado pela seguinte expressão:

$$EB_{\text{aut}} = [N^{\text{BC}} \times (N^{\text{A}} + 1) \times 23 \times 17^{\kappa}]^{NB_{\text{max}}} \quad (23)$$

sendo N^{A} a cardinalidade do conjunto de BCs automáticos.

Os valores representados pelas equações 22 e 23 correspondem ao espaço de busca mínimo e máximo, respectivamente. Quando são alocados BCs fixos e automáticos concomitantemente, o espaço de busca será intermediário a estes valores.

4.2 Determinação da população inicial

A população inicial é gerada aleatoriamente, de acordo com os limites estabelecidos para cada gene, conforme a Figura 12. O número de indivíduos gerados é maior que o número de indivíduos da população n_{pop} definida no início; esse excesso de indivíduos permite obter n_{pop} indivíduos diferentes na população. O processo empregado para a geração da população inicial compreende cinco etapas:

1. geração aleatória de uma população temporária com $5n_{\text{pop}}$ indivíduos;

2. considerando os $5n_{\text{pop}}$ indivíduos da população temporária, selecionar $2n_{\text{pop}}$ indivíduos distintos; assume-se que dois indivíduos são considerados distintos se a diferença em suas normas euclidianas for maior que um valor pré-definido ($d_{\text{init}}^{\text{min}}$);
3. determinar a função de adaptação de todos $2n_{\text{pop}}$ indivíduos e classificá-los do melhor para o pior indivíduo de acordo com os valores de adaptação;
4. selecionar os melhores n_{pop} indivíduos para compor a população inicial;
5. selecionar os primeiros n_{eli} indivíduos distintos, cuja diferença em suas normas seja maior que $d_{\text{eli}}^{\text{min}}$, para compor a elite inicial.

Os valores das diferenças mínimas ($d_{\text{init}}^{\text{min}}$, $d_{\text{pop}}^{\text{min}}$ e $d_{\text{eli}}^{\text{min}}$), utilizadas para comparar os indivíduos da população, são definidos quando o processo de otimização é iniciado e podem ser atualizados durante a sua execução, para ajustar a diversidade da população. As diferenças mínimas começam com seus valores máximos e, na sequência, são reduzidas linearmente ao mínimo. As populações subsequentes são obtidas conforme descrito a seguir:

1. gerar uma população composta dos seguintes indivíduos;
 - n_{eli} indivíduos históricos da elite contendo as melhores soluções obtidas até este ponto;
 - n_{rec} indivíduos resultantes da recombinação de membros da última população;
 - n_{mut} indivíduos resultantes da mutação de membros da última população.
2. os indivíduos distintos da população são selecionados de forma que a norma euclidiana entre esses indivíduos seja maior que o limite inferior ($d_{\text{pop}}^{\text{min}}$);
3. complementar a população com indivíduos da população anterior, ordenados do melhor indivíduo para o pior, até atingir o número de indivíduos de n_{pop} .

Caso desejado, é possível considerar as curvas usuais de demanda e restringir os valores de alguns genes, tanto no horário que os BCs ligam quanto na duração de funcionamento dos mesmos, a partir da análise dos valores com a maior probabilidade de ocorrência. Com essa estratégia, é possível gerar indivíduos com boa adaptação já na população inicial. Cabe salientar que este direcionamento na população inicial não impede que os operadores do AG modifiquem os valores destes genes no decorrer da otimização.

4.3 Função de adaptação

No contexto de otimização utilizando AGs, é prática comum utilizar funções de adaptação ao invés de funções objetivo. Uma função de adaptação pode ser obtida a partir de uma determinada função objetivo; em alguns casos, pode até coincidir com a função objetivo, como é o caso do problema proposto neste trabalho. Assim, a função de adaptação desempenha o mesmo papel que a função objetivo nos métodos clássicos de otimização, pois permite obter soluções ótimas, que também estão associadas a valores máximos e mínimos. Portanto, funções de adaptação descrevem a qualidade de cada indivíduo em relação a aspectos específicos.

No problema de otimização proposto, a qualidade dos indivíduos da população é avaliada a partir da minimização da função objetivo representada pela equação (3), a qual considera os custos de investimento e operação dos BCs. Esta função pode considerar ou não de forma simultânea duas parcelas, na qual a primeira representa o custo das violações nos níveis de tensão e a segunda, o custo das perdas de energia, conforme as equações (8) e (11).

4.4 Seleção


A seleção de pais para a aplicação da recombinação – denominados pai_1 e pai_2 – é realizada por meio de torneios, o que é uma forma usual de selecionar indivíduos da população quando AGs são utilizados. Cada pai é o vencedor de um torneio que ocorre entre n_{tor} indivíduos selecionados aleatoriamente. Além disso, para evitar a seleção de dois pais idênticos, o primeiro pai selecionado (pai_1) é excluído da seleção do segundo pai (pai_2). Para a mutação, a seleção também é realizada por meio de torneio, sendo selecionado apenas um pai .

4.5 Recombinação

O processo de recombinação adotado neste trabalho consiste em gerar seis descendentes para cada par de pais selecionados (pai_1 e pai_2). Estes descendentes são gerados aplicando três tipos diferentes de recombinação (HAFFNER; PEREIRA; PEREIRA, 2015). Como forma de ilustrar as recombinações, os pais selecionados foram gerados considerando a alocação de 2 BCs e a consideração de 3 cenários

representativos, em um sistema com 22 nós candidatos e 5 tipos disponíveis de BCs, conforme ilustrado pela Figura 14 e descrito a seguir:

Figura 14: Operadores do AG, representados por: (a) recombinação simples, (b) recombinação aritmética e (c) recombinação discreta.



Fonte: Elaborada pelo autor.

- (a) recombinação simples: um ponto de corte aleatório é obtido e os dois descendentes são então gerados como ilustrado na Figura 14(a);
- (b) recombinação aritmética: primeiramente um número aleatório $\lambda \in \mathbb{R}$, $0, 1 \leq \lambda \leq 0,4$ é gerado e os dois descendentes são então obtidos por combinação linear dos pais de acordo com as equações dadas a seguir. Os valores inteiros mais próximos de cada gene no cromossomo são escolhidos e utilizados, como mostrado na Figura 14(b).

$$descendente_1 = \lambda \cdot pai_1 + (1 - \lambda) \cdot pai_2 \quad (24)$$

$$descendente_2 = (1 - \lambda) \cdot pai_1 + \lambda \cdot pai_2 \quad (25)$$

(c) recombinação discreta: o conteúdo dos genes do primeiro descendente (*descendente₁*) é obtido do conteúdo dos genes correspondentes de seus pais, através de uma máscara de números binários gerada aleatoriamente; o conteúdo dos genes do segundo descendente (*descendente₂*) é obtido a partir dos valores não utilizados pelo primeiro descendente (*descendente₁*); este processo é ilustrado na Figura 14(c);

4.6 Mutação

No processo de mutação, indivíduos vencedores de torneio entre indivíduos escolhidos aleatoriamente são selecionados. Como variáveis inteiras são utilizadas, o processo de mutação muda apenas o valor do gene definido aleatoriamente de acordo com a distribuição de probabilidade descrita na sequência:

- 30% são aumentados em uma unidade;
- 30% são diminuídos em uma unidade;
- 40% são alterados aleatoriamente, assumindo um valor entre os valores mínimo e máximo permitidos para o gene correspondente.

Quando o valor do gene é aumentado em uma unidade e o limite superior é excedido, seu valor é alterado para o limite inferior. De modo análogo, quando o limite inferior é excedido, o valor do gene é alterado para o limite superior.

A fim de realizar uma busca mais profunda em torno das melhores soluções, o processo de mutação é aplicado também a todos os indivíduos pertencentes à elite. A probabilidade de aumento, redução ou mudança aleatória é a mesma que para todos os demais.

4.7 Busca Local e Intensificação

Pelo fato dos AGs serem essencialmente não-determinísticos e pela pouca informação que se detém sobre a vizinhança de uma solução válida, explorar a vizinhança de qualquer solução válida pode não apenas melhorar a qualidade da melhor solução obtida, mas também impedir que uma solução promissora seja perdida durante o processo de otimização. Com isso, uma intensificação no procedimento de busca, ou seja, uma busca local em torno de uma boa solução, é realizada. Além disso, de

maneira a reter as possíveis melhores soluções já determinadas, a elite histórica – indivíduos na elite da geração anterior – é armazenada independentemente. Dessa forma, a cada geração, uma intensificação é realizada em torno de um dos indivíduos da elite, selecionado aleatoriamente. O procedimento de intensificação é brevemente descrito pelos seguintes passos:

1. partindo de uma das melhores soluções obtida até o momento, é formada uma população temporária contendo todas as soluções vizinhas diferindo em uma posição o valor dos genes (primeira vizinhança);
2. se o melhor indivíduo da população temporária for melhor que o indivíduo avaliado pela busca local, ele assumirá o lugar do indivíduo avaliado; caso contrário, o indivíduo da elite permanece o mesmo.

O número de indivíduos da população temporária da busca local é o dobro do número de genes que descrevem um indivíduo.

5 VALIDAÇÃO E APLICAÇÃO DO MODELO PROPOSTO

Neste capítulo, são apresentados os resultados da elaboração dos cenários representativos da demanda de diferentes classes de consumidores e de GDs compostas por sistemas fotovoltaicos, além da validação e estudo de caso para o modelo de compensação de potência reativa proposto.

O modelo proposto foi implementado por intermédio da integração do *software* OpenDSS com o MATLAB®, no qual os fluxos de potência são resolvidos via *COM Interface* com o OpenDSS. Um computador com processador Intel Core i7-4700HQ CPU @ 2.40GHz 8GB de RAM, com sistema operacional 64 bits foi utilizado nas simulações.

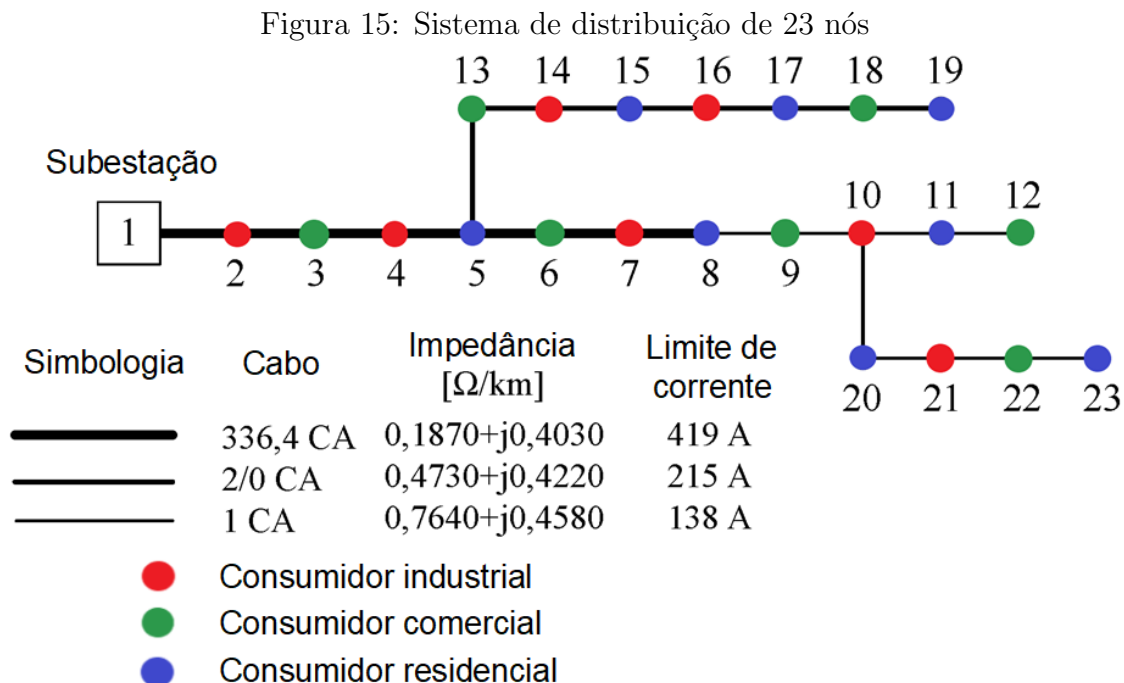
5.1 Validação dos Cenários de demanda e GD

Nesta seção, são apresentados o sistema de distribuição utilizado e os dados coletados para a geração e validação dos cenários de demanda e GD. São detalhadas as especificações do sistema teste, as curvas de carga utilizadas e a metodologia para a geração da incerteza atribuída, bem como os dados históricos de geração fotovoltaica para a contabilização da incerteza inerente as fontes intermitentes. Por fim, são apresentados os resultados dos testes realizados para validar os cenários representativos obtidos.

5.1.1 Sistema de distribuição de 23 nós

O sistema de 23 nós opera em 13,8 kV, com uma carga nominal de 4158 kW e 2728 kvar (HAFFNER et al., 2009), distribuída igualmente entre os nós 2 a 23. A Figura 15 apresenta o diagrama deste sistema, onde podem ser visualizados os dados das linhas e condutores e a segmentação das classes de consumidores entre os

nós, no qual os nós em vermelho, verde e azul representam consumidores industriais, comerciais e residenciais, respectivamente. A configuração base do sistema de 23 nós foi definida considerando que nenhum capacitor ou GD está instalado.



Fonte: Adaptado de (RESENER, 2016).

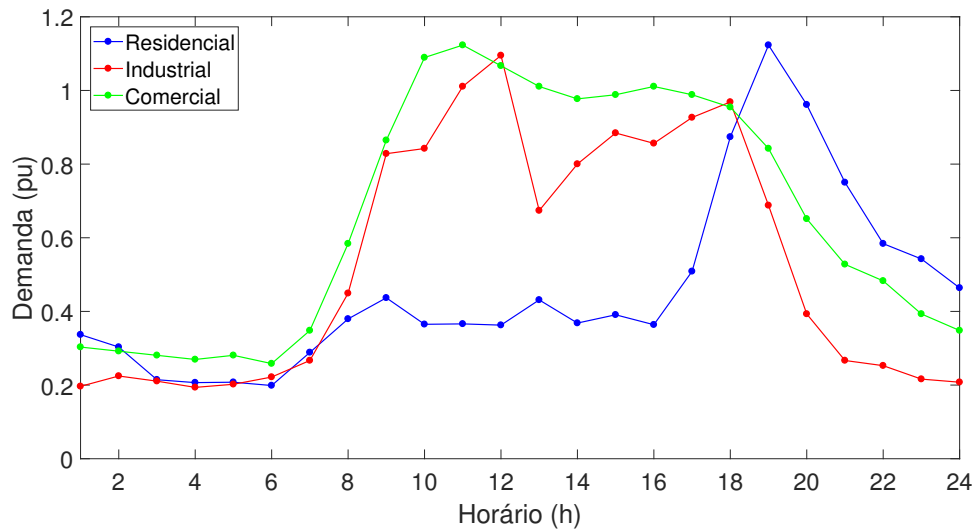
5.1.1.1 Curvas de carga adotadas

Tendo em vista a dificuldade na obtenção de dados reais de consumo junto a distribuidoras de energia elétrica, optou-se por gerar artificialmente curvas de carga com grande variabilidade, no qual este parâmetro pode ser controlado. Com isso, foram selecionadas curvas de carga típicas de consumidores industriais, comerciais e residenciais, para posterior geração de curvas aleatórias com a aplicação de incertezas, conforme detalhado na Seção 5.1.2.

As Figuras 16, 17 e 18 ilustram curvas de carga diárias típicas de consumidores industriais, comerciais e residenciais para dias úteis, sábados e domingos, respectivamente. A demanda é horária e representada em valores por unidade ao longo de 24 horas.

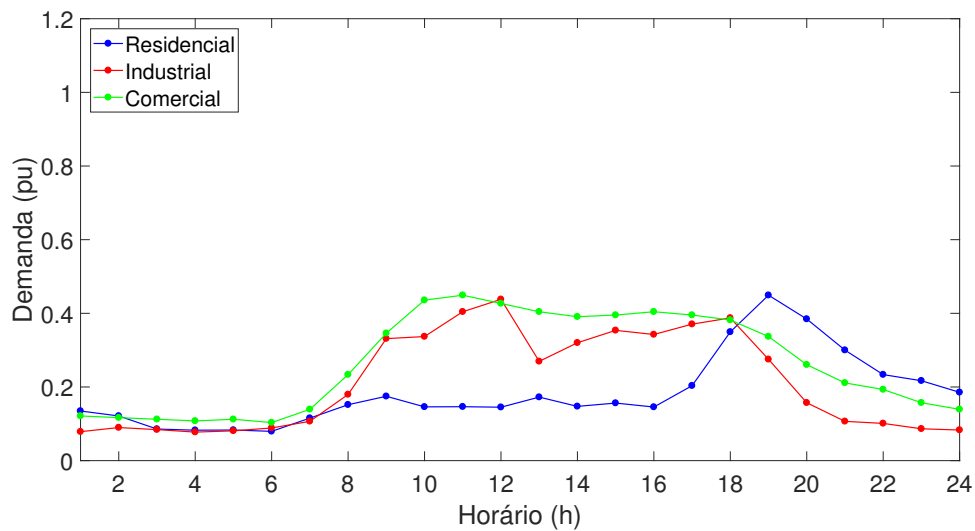
Pode-se observar a partir das Figuras 16, 17 e 18, que o aumento ou diminuição da demanda de carga dos diferentes tipos de consumidores pode ou não coincidir, de modo que é criada uma diversidade de consumo entre os nós do sistema de distribuição.

Figura 16: Curvas de carga diárias típicas de consumidores industriais, comerciais e residenciais para dias úteis



Fonte: Elaborada pelo autor.

Figura 17: Curvas de carga diárias típicas de consumidores industriais, comerciais e residenciais para sábados




Fonte: Elaborada pelo autor.

5.1.2 Cenários de curvas de carga representativas

A geração de curvas de carga artificiais é realizada através da aplicação de incertezas nas curvas de carga típicas das Figuras 16, 17 e 18. A modelagem desta incerteza é realizada com a elaboração de curvas de carga na qual a demanda a cada instante de tempo t para o nó i é dada por:

Figura 18: Curvas de carga diárias típicas de consumidores industriais, comerciais e residenciais para domingos.



Fonte: Elaborada pelo autor.

$$d_i(t) = [1 + \Delta\delta_i(t)] \cdot d_i^{nom}(t) \quad (26)$$

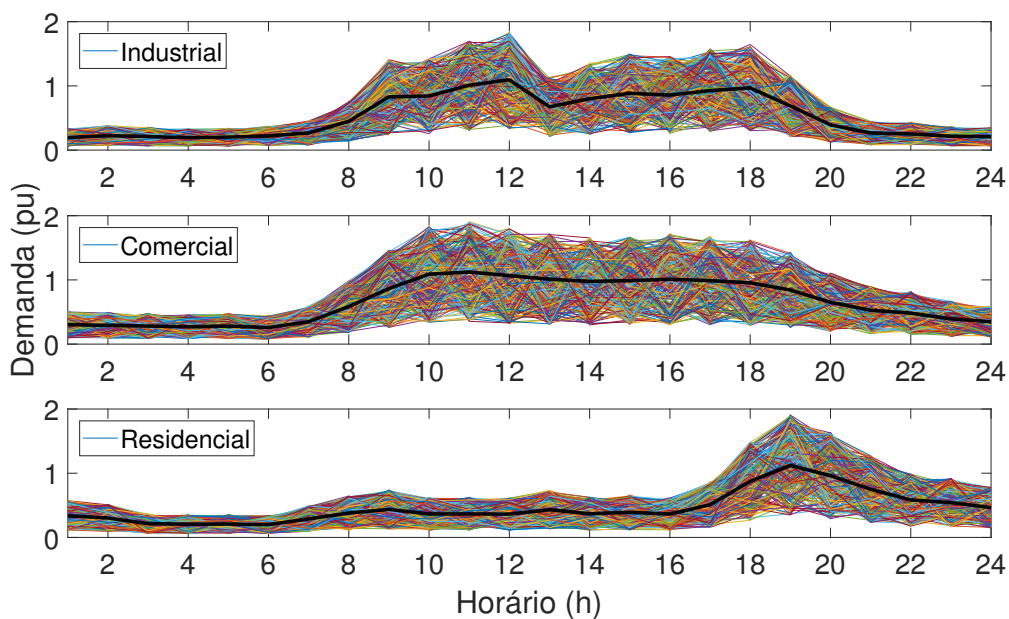
onde Δ é a variação máxima arbitrada, $\delta_i(t) \in [-1; 1]$ é um número aleatório uniformemente distribuído atribuído para o nó i no instante t e $d_i^{nom}(t)$ é a demanda nominal do nó i no instante de tempo t .

As curvas de carga artificiais diárias geradas para três nós do sistema da Figura 15 são ilustradas pela Figura 19, na qual são representados: nó 2 com consumidores industriais, nó 3 com consumidores comerciais e o nó 23 com consumidores residenciais, respectivamente. As curvas geradas representam a totalidade de dias úteis de um ano, considerando um Δ de 70%. A demanda é representada por unidade e as curvas de carga nominais são representadas em preto pela linha mais espessa.

De forma análoga à Figura 19, as Figuras 20 e 21 ilustram as curvas de carga artificiais geradas para sábados e domingos, dias que representam curvas de carga com demanda menor e por consequência há uma reduzida variação absoluta da incerteza modelada.


A Figura 22 ilustra as mesmas curvas de carga das Figuras 19, 20 e 21, mas visualizadas ao longo das 8760 horas do ano. São representadas as curvas dos nós 2, 3 e 23 considerando um Δ de 70%. Cabe salientar que para cada nó do sistema, são geradas distintas curvas de carga para cada dia ao longo de 365 dias.

Figura 19: Curvas de carga diárias geradas artificialmente para os nós 2, 3 e 23, respectivamente, em dias úteis, com Δ de 70%.



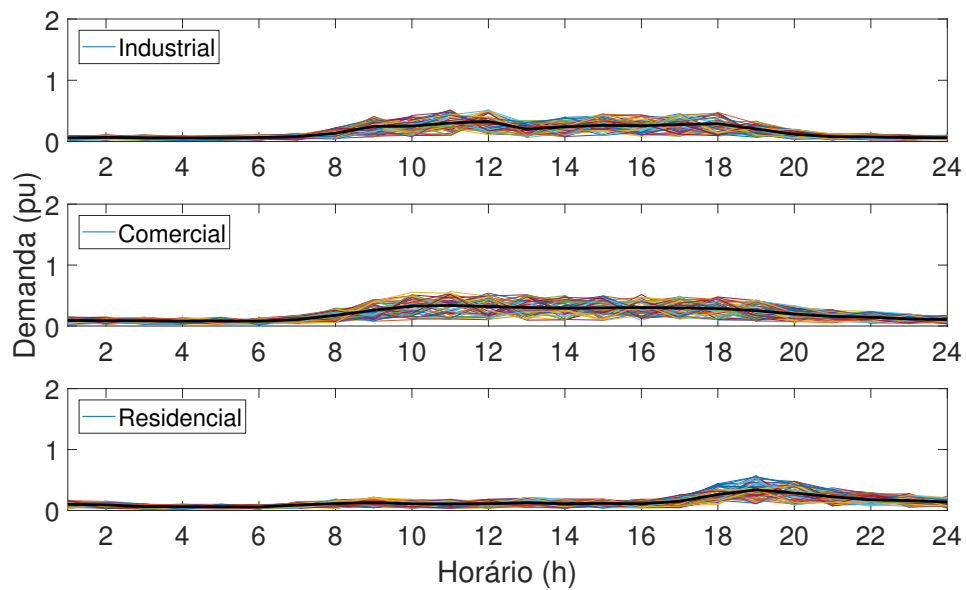
Fonte: Elaborada pelo autor.

Figura 20: Curvas de carga diárias geradas artificialmente para os nós 2, 3 e 23, respectivamente, aos sábados, com Δ de 70%.




Fonte: Elaborada pelo autor.

Figura 21: Curvas de carga diárias geradas artificialmente para os nós 2, 3 e 23, respectivamente, aos domingos, com Δ de 70%.



Fonte: Elaborada pelo autor.

Figura 22: Curvas de carga diárias geradas artificialmente para os nós 2, 3 e 23, respectivamente, ao longo de um ano.

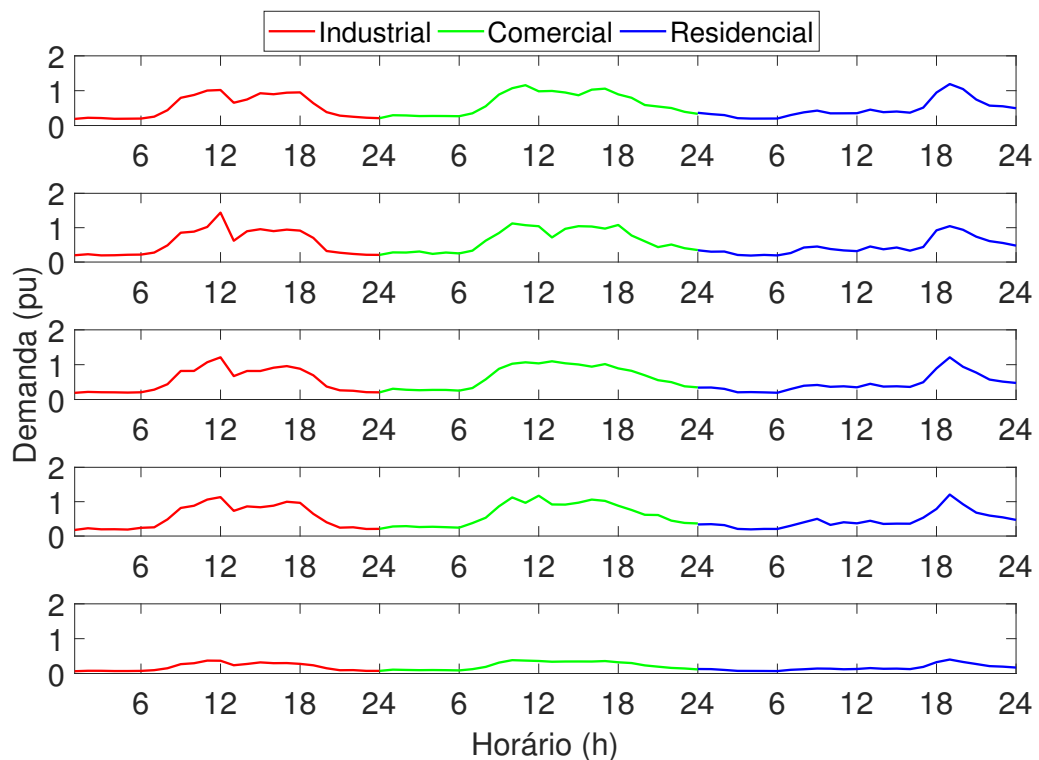


Fonte: Elaborada pelo autor.

Definidos os valores horários para todo o ano, foi empregada a técnica de clusterização *K-means* para a geração de cenários de curvas de carga representativas considerando a variação do número de \mathcal{K} cenários. O intuito é reduzir o número de dias representativos de um ano, de 365 dias para \mathcal{K} cenários, de forma que os cenários gerados possam representar o ano com boa precisão.

A Figura 23 ilustra os cenários obtidos para descrever o comportamento diário de 3 diferentes consumidores, a partir da aplicação do *K-means*, para compactar as 365 curvas de carga artificiais em 5 curvas de carga representativas, utilizando $\mathcal{K} = 5$.

Figura 23: Cenários de curva de carga obtidas a partir do *K-means* com 5 *clusters*.



Fonte: Elaborada pelo autor.

Na Figura 23, cada cenário ilustra as curvas de carga de nós com consumidores industriais, comerciais e residenciais, respectivamente, representados em sequência mas com atuação concomitante. Pode-se observar a distinção entre as curvas de carga de cada cenário obtido, no qual cada cenário tem uma probabilidade maior ou menor de ocorrência. É visível, por exemplo, que o quinto cenário representa o agregado das curvas de carga artificiais que representam os finais de semana, contemplando sábados e domingos. Já os demais cenários, representam dias úteis.

A Tabela 5 apresenta uma comparação dos valores obtidos na aplicação de diferentes valores da variação Δ e do número de \mathcal{K} cenários empregados. São apresentados os resultados da energia de perdas anual do sistema e da soma das violações nos níveis de tensão (Z), calculada a partir da equação (20), no sistema de 23 nós para duas situações distintas. O índice Z considera como limites mínimo e máximo de tensão os valores 0,93 pu e 1,05 pu, de acordo com a faixa de tensão adequada para a tensão nominal do sistema de 23 nós (ANEEL, 2018).

Na Tabela 5, a coluna 1 apresenta a variação do número de *clusters* gerados pelo *K-means*, representando \mathcal{K} cenários. A coluna 2 apresenta a variação máxima arbitrada para a elaboração das curvas de carga artificiais, através da variável Δ . As colunas 3 a 6 apresentam os resultados obtidos a partir da geração de curvas de carga artificiais horárias, com 24 valores. Já as colunas 7 a 10 apresentam os resultados da geração de curvas de carga diárias sintetizadas por 8 patamares com 3 horas de duração cada. Os patamares representam a média a cada 3 horas dos valores gerados das curvas de carga horárias. Portanto, as colunas 3 e 7 e as colunas 4 e 8 apresentam a comparação dos valores da energia de perdas dos 365 dias gerados com o número de \mathcal{K} cenários gerados, respectivamente. Já as colunas 5 e 9 e as colunas 6 e 10 apresentam a comparação entre a soma das violações dos limites de tensão nos panoramas com 365 dias e com \mathcal{K} cenários.

Pode-se observar uma grande proximidade entre os valores obtidos quando são considerados 2 ou mais cenários representativos, o que ocorre devido a separação do agregado das curvas de carga artificiais de finais de semana em um ou mais cenários. Quando é considerado apenas uma curva de carga representativa, os dias úteis, sábados e domingos são representados por apenas um cenário, o que justifica a diferença significativa frente aos resultados dos demais cenários. Com o incremento da variação Δ , os valores obtidos para 365 dias e \mathcal{K} cenários representativos tendem a ficar mais distantes, mas uma boa aproximação é obtida mesmo assim, principalmente com o incremento do número de cenários. Na situação em que foi considerada uma variação $\Delta = 0\%$, 3 cenários são o suficiente para a representação das curvas de carga (dia útil, sábado e domingo), pois não há incerteza agregada a estas curvas.

O tempo de simulação, para os diferentes casos analisados na Tabela 5, varia entre 7,5 e 15 segundos, na qual é considerada uma linha da Tabela 5 que gera

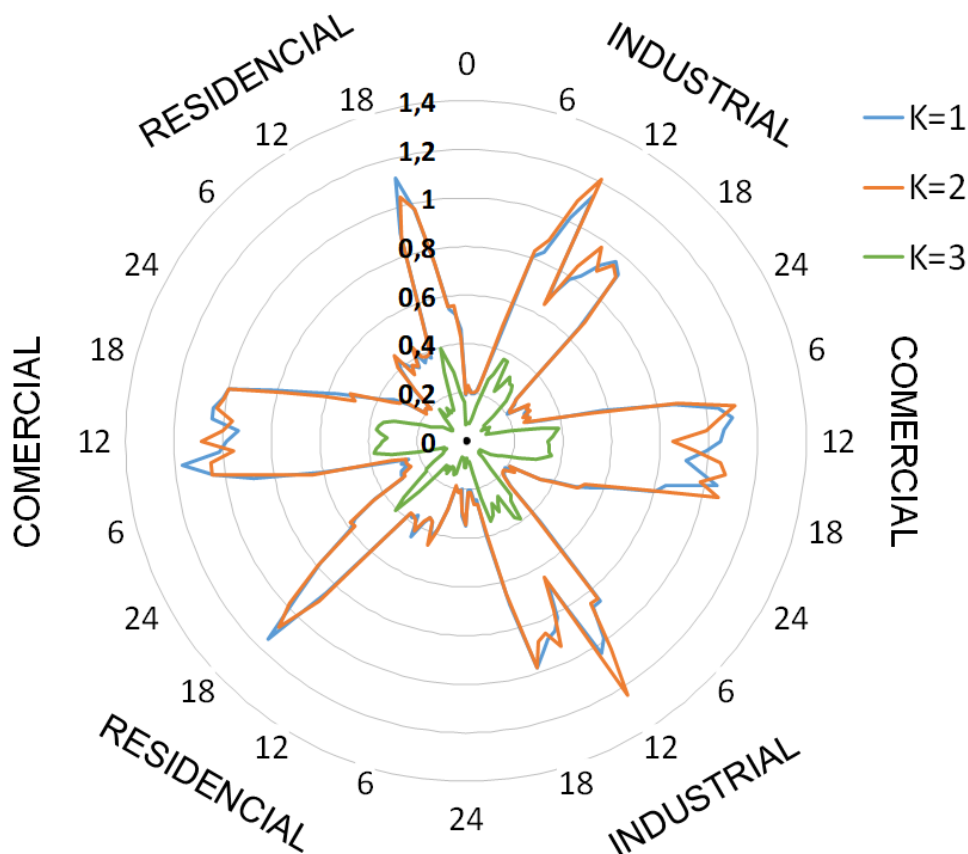
Tabela 5: Comparação dos resultados obtidos na geração de curvas de carga representativas através do *K-means* para curvas diárias com 24 valores e com 8 patamares.

Número de cenários (κ)	Δ	Curva de carga - 24 valores				Curva de carga - 8 patamares de 3h				
		Perdas (MWh/ano)		Z (pu)		Perdas (MWh/ano)		Z (pu)		
		365 dias	κ cenários	365 dias	κ cenários	365 dias	κ cenários	365 dias	κ cenários	
1	0%		607,67		0,0764		594,59		0,0656	
2		689,04	688,29	0,1386	0,1386	674,04	673,40	0,1279	0,1279	
3			689,04		0,1386		674,04		0,1279	
1	10%		607,73		0,0765		594,64		0,0656	
2			688,34		0,1386		673,42		0,1278	
3		689,34	688,44	0,1387	0,1386	674,15	673,44	0,1279	0,1278	
5			688,45				673,59			0,1279
10			689,09				673,68			0,1279
100			689,17				674,09			0,1279
1	30%		607,85		0,0765		594,74		0,0656	
2			688,54		0,1386		673,47		0,1278	
3		691,52	688,56	0,1393	0,1386	674,89	673,48	0,1280	0,1278	
5			688,60				673,51			0,1278
10			689,25				673,53			0,1279
100			689,97				674,40			0,1279
1	50%		607,98		0,0766		594,84		0,0656	
2			688,65		0,1385		673,53		0,1277	
3		695,79	688,72	0,1407	0,1386	676,64	673,60	0,1285	0,1277	
5			688,82				673,62			0,1278
10			689,50				674,32			0,1278
100			691,49				674,97			0,1280
1	70%		608,12		0,0766		594,94		0,0657	
2			688,77		0,1385		673,58		0,1277	
3		702,17	688,91	0,1428	0,1385	678,50	674,19	0,1292	0,1277	
5			689,10				674,31			0,1278
10			689,84				674,90			0,1278
100			693,59				675,81			0,1282
1	90%		608,27		0,0767		595,05		0,0657	
2			688,91		0,1385		673,65		0,1276	
3		710,66	689,13	0,1455	0,1385	681,37	673,77	0,1302	0,1276	
5			689,46				673,96			0,1277
10			690,25				675,16			0,1278
100			696,35				676,90			0,1286

cenários tanto para as curvas de carga artificiais com 24 valores, quanto para as curvas com 8 patamares de 3 horas de duração. Ao considerar apenas a geração dos cenários com 24 valores, o tempo de simulação varia entre 5,5 e 12 segundos. Como forma de validação da técnica de clusterização, foram simulados os casos com $K = 365$ e nesta situação o tempo de simulação variou entre 69 e 77 segundos.

Outra forma de ilustrar as curvas de carga obtidas para os diferentes nós do sistema de 23 nós é através da Figura 24, a qual representa um gráfico do tipo radial com as curvas de carga representativas de 6 nós do sistema, sendo considerados 3 cenários.

Figura 24: Cenários de curva de carga obtidas a partir do *K-means* com 3 *clusters*.



Fonte: Elaborada pelo autor.

Na Figura 24, as curvas de carga são diárias e representam 24 horas concomitantes para os nós. As linhas de nível radiais ilustram a demanda por unidade das curvas de carga. São representados dois nós do sistema com cada tipo de consumidor: industrial, comercial e residencial, o que possibilita visualizar a diferença das curvas de carga geradas para distintos nós com o mesmo tipo de consumidor.

Além disso, pode-se observar que os cenários $K=1$ e $K=2$ representam dias úteis e o cenário $K=3$ representa o agregado de sábados e domingos.

Por fim, cabe salientar que no presente trabalho, para o sistema de 23 nós, apenas a potência ativa é modelada como variável aleatória. A potência reativa varia com a potência ativa de acordo com um fator de potência constante, definido como 0,836.

5.1.3 Cenários de geração fotovoltaica

A geração de cenários representativos de GDs oriundas de fonte solar fotovoltaica é realizada através da coleta de dados históricos de irradiação solar de 10 anos na área que compreende a cidade de Porto Alegre, Rio Grande do Sul. Os dados de irradiação e geração foram obtidos através da ferramenta digital *Renewables Ninja* (PFENNINGER; STAFFELL, 2016).

Os dados de geração fotovoltaica do *Renewables Ninja* utilizam o banco de dados meteorológico MERRA-2. Os parâmetros utilizados para a obtenção dos dados de geração fotovoltaica foram:

- Cidade: Porto Alegre/RS;
- Capacidade instalada: 500 kW;
- Perdas do sistema: 5 %;
- Sistema de rastreamento: sem rastreamento;
- Inclinação dos módulos: 24°;
- Orientação dos módulos: Norte geográfico.

A inclinação dos módulos foi definida de acordo com pesquisas do Centro de Referência para Energia Solar e Eólica Sérgio de Salvo Brito (CRESESB, 2018), o qual demonstra que para a cidade de Porto Alegre/RS, a irradiação solar no plano inclinado com uma inclinação de 24° e orientação geográfica norte, propicia a maior geração anual de energia elétrica.

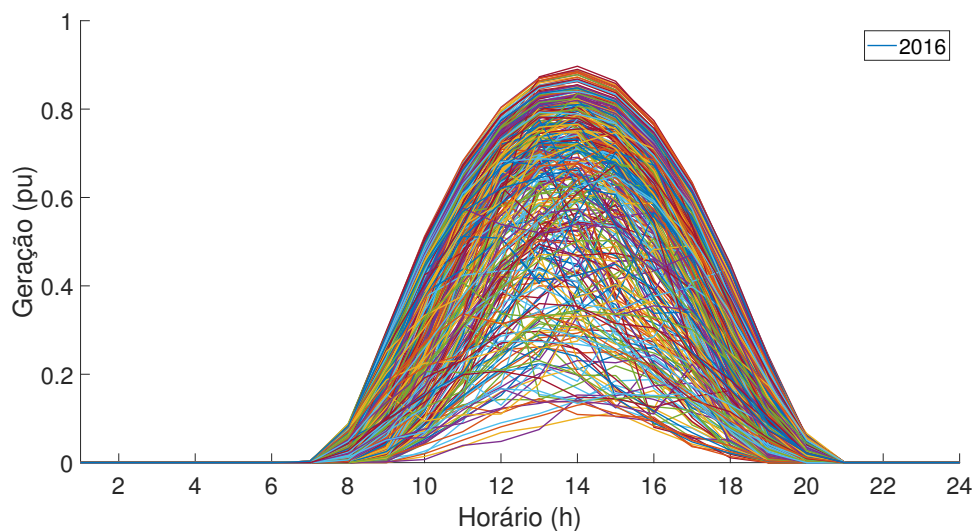
O histórico de geração para os anos de 2007 a 2016, com os parâmetros definidos anteriormente, é apresentado na Tabela 6. A coluna 1 apresenta o histórico de anos coletados, a coluna 2 apresenta o fator de capacidade da geração de forma percentual e a coluna 3 apresenta a geração anual de energia em MWh.

Tabela 6: Histórico de geração anual para a cidade de Porto Alegre

Ano	Fator de Capacidade (%)	Geração anual (MWh)
2007	19,0	830,28
2008	19,7	860,44
2009	19,0	834,09
2010	18,9	827,32
2011	19,6	857,01
2012	19,7	863,74
2013	19,9	872,57
2014	19,0	832,21
2015	18,1	791,87
2016	18,9	826,44

A Figura 25 ilustra as curvas de geração solar fotovoltaica horárias para o ano de 2016, na qual a geração é representada por unidade. Cada curva representa 24 horas com resolução horária. Pode-se observar uma grande variabilidade entre as curvas de geração, principalmente por englobar diferentes estações e condições climáticas diversas ao longo do ano. No entanto, há predomínio de curvas que acompanham a forma senoidal, característica da geração fotovoltaica.

Figura 25: Curvas históricas de geração fotovoltaica para o ano de 2016.



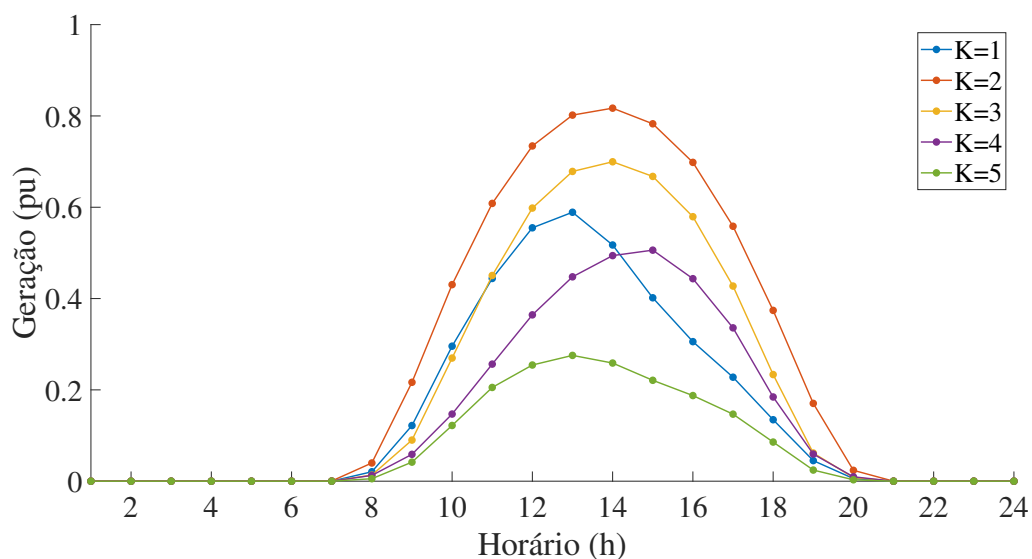
Fonte: Elaborada pelo autor.

Dessa forma, foi empregada a técnica de clusterização *K-means* para a obtenção

de cenários de geração fotovoltaica. O intuito é reduzir o número de dias representativos para o histórico coletado, de forma que os cenários gerados possam representar de forma fiel o período analisado com o menor número de cenários possível.

A Figura 26 ilustra os cenários de geração obtidos a partir da aplicação do *K-means* para compactar as 365 curvas de geração fotovoltaica referentes ao ano de 2016 em 5 cenários de geração representativos.

Figura 26: Cenários de geração fotovoltaica obtidos a partir do *K-means* com 5 *clusters* para o ano de 2016.



Fonte: Elaborada pelo autor.

De forma a visualizar a probabilidade de ocorrência de cada cenário gerado na Figura 26, são apresentados na Tabela 7 os dados estatísticos destes cenários considerando apenas o ano de 2016. A coluna 1 apresenta os cenários considerados, a coluna 2 o número de dias por ano que cada cenário representa, a coluna 3 apresenta a probabilidade de ocorrência de cada cenário e a coluna 4 a geração diária em kWh. A última linha representa a geração anual de energia em MWh através do somatório das gerações diárias e suas probabilidades anuais, considerando os 5 cenários utilizados – observar que a geração anual obtida pelos 5 cenários é idêntica àquela obtida considerando todos os valores horários do histórico do respectivo ano, vide Tabela 6.

A partir da Figura 26 e da Tabela 7, é possível visualizar que os cenários $K = 2$ e $K = 3$ tem maior probabilidade de ocorrência por representar dias com maior geração e dias com geração intermediária, mas mantendo a forma senoidal característica.

Tabela 7: Probabilidade dos cenários de geração FV com 5 *clusters* referentes a Figura 26.

Cenário (K)	Ocorrência (dias/ano)	Probabilidade (%)	Geração diária (kWh)
1	34	9,32 %	1832,12
2	117	32,06 %	3128,32
3	114	31,23 %	2388,76
4	46	12,60 %	1659,91
5	54	14,79 %	915,84
Geração anual (MWh)			826,44

O cenário $K = 5$ possivelmente representa dias chuvosos e/ou nublados.

Com o intuito de validar a geração de cenários representativos de gerações fotovoltaicas e considerando a posterior alocação de compensação de potência reativa no sistema de 23 nós, na Seção 5.2, foram definidas as potências nominais e os nós do sistema onde serão alocadas as GDs, sendo:

- Nó 8: Geração de 500 kW;
- Nó 16: Geração de 500 kW;
- Nó 20: Geração de 500 kW.

A alocação foi realizada nestes locais, conforme a Figura 15, por serem nós posicionados em centros de consumo do sistema de 23 nós e portanto, com maior probabilidade de reduzir as violações nos níveis de tensão e as perdas no sistema de distribuição. Dessa forma, a intermitência das fontes renováveis é levada em consideração na solução do problema.

Uma maneira de incluir uma variabilidade adicional ao comportamento da geração fotovoltaica, para que seja possível realizar uma simulação anual, é definir que cada nó do sistema onde foi alocada uma GD seja representado pelo histórico de geração de um ano diferente. Com isso, foi realizada a seguinte alocação:


- Nó 8: Geração do ano 2013 (maior geração anual);
- Nó 16: Geração do ano 2015 (menor geração anual);

- Nó 20: Geração do ano 2009 (geração anual mais próxima da média do histórico).

Cabe salientar que embora cada nó com GD contemple um ano do histórico de geração no estudo de caso, assume-se que as gerações ocorrem concomitantemente para que seja possível simular um ano de operação do sistema de 23 nós.

A Figura 27 ilustra a aplicação do *K-means* para compactar as curvas de geração fotovoltaica nos 3 nós do sistema com GD em 5 cenários representativos, os quais representam o histórico de geração dos anos de 2013, 2015 e 2009, respectivamente.

Figura 27: Cenários de geração fotovoltaica simultâneos obtidos a partir do *K-means* com 5 *clusters* para os anos de 2013, 2015 e 2009, respectivamente.



Fonte: Elaborada pelo autor.

De forma a visualizar a probabilidade de ocorrência de cada cenário gerado na Figura 27, é apresentado na Tabela 8 os dados estatísticos destes cenários para os 3 nós em questão. A coluna 1 apresenta os cenários considerados, a coluna 2 o número de dias por ano que cada cenário representa e a coluna 3 apresenta a probabilidade de ocorrência. As colunas 4 a 6 apresentam a geração de energia diária em kWh de cada cenário representativo para os nós 8, 16 e 20 da Figura 27. A última linha representa a geração anual de energia em MWh para cada nó, os quais representam um ano diferente do histórico da Tabela 6. Cabe salientar que os valores obtidos pelos 5 cenários são idênticos aos obtidos considerando todos os valores horários dos respectivos anos.

Tabela 8: Probabilidade e geração de energia dos cenários de geração fotovoltaica referentes a Figura 27.

Cenário (K)	Ocorrência (dias/ano)	Probabilidade (%)	Geração diária (kWh)		
			Nó 8	Nó 16	Nó 20
1	59	16,16	2286,20	1116,75	2683,45
2	52	14,25	2653,24	1434,22	1339,33
3	140	38,36	2824,92	2606,95	2881,20
4	55	15,07	2549,36	2693,01	1325,36
5	59	16,16	1084,94	2344,23	2201,08
Geração anual (MWh)			872,57	791,87	834,09

A partir da Figura 27 e da Tabela 8, é possível visualizar a variabilidade das GDs fotovoltaicas através dos cenários representativos, pois da forma como as séries históricas foram modeladas, os nós podem ou não ter a mesma geração a cada instante de tempo. As gerações nos nós 8, 16 e 20 ocorrem simultaneamente, mas cada nó segue uma curva de geração distinta. Desta forma foi obtida a variabilidade desejada.

Pode-se observar, por exemplo, que o cenário $K = 3$ representa a maior geração de energia nos nós 8 e 20, e a segunda maior geração no nó 16, com curvas de geração semelhantes. O cenário $K = 1$ representa uma curva de geração intermediária no nó 8, a menor geração no nó 16 e a segunda maior geração no nó 20. Já o cenário $K = 2$ representa uma geração elevada apenas no nó 8, tendo a segunda menor geração nos nós 16 e 20, como pode ser visto pelos dados de geração diária da Tabela 8. Da mesma forma, os demais cenários representativos também apresentam distintas curvas de geração de energia para cada nó.

5.1.4 Cenários de combinação carga-GD

Ao considerar a geração de cenários tanto da carga quanto de GDs, aplicados a um sistema de potência, torna-se necessário gerar combinações do conjunto carga-GD quando são gerados mais do que um cenário representativo. Como exemplo de aplicação, a Tabela 9 apresenta as probabilidades de ocorrência dos cenários representativos da carga com $\kappa = 2$ e Δ de variação de 70% e os cenários representativos

da GD com $\kappa = 5$ da Tabela 8, além das probabilidades de ocorrência do conjunto dos cenários.

Na Tabela 9, as colunas 1 a 3 apresentam os dados relativos aos cenários da carga, as colunas 4 a 6 apresentam os dados relativos aos cenários das GDs e por fim, as colunas 7 e 8 apresentam os dados relativos aos cenários do conjunto carga-GD. As colunas 1 e 4 apresentam a enumeração dos cenários relativos a carga e a GD, respectivamente. As colunas 2, 5 e 7 apresentam o número de dias por ano que cada cenário representa e as colunas 3, 6 e 8 a probabilidade de ocorrência.

Tabela 9: Probabilidade conjunta de cenários representativos da carga com $\kappa = 2$ e da GD com $\kappa = 5$.

Cenários - carga			Cenários - GD			Conjunto carga-GD	
K	Dias/ano	Prob. (%)	K	Dias/ano	Prob. (%)	Dias/ano	Prob. (%)
1	104	28,49	1	63	17,26	17,96	4,92
			2	50	13,70	14,24	3,90
			3	139	38,08	39,60	10,85
			4	49	13,42	13,95	3,82
			5	64	17,53	18,25	5,00
2	261	71,51	1	63	17,26	45,04	12,34
			2	50	13,70	35,76	9,80
			3	139	38,08	99,39	27,23
			4	49	13,42	35,04	9,60
			5	64	17,53	45,77	12,54

A partir da Tabela 9, pode-se observar que ao considerar 2 cenários de carga, o primeiro cenário contabilizou 104 dias, o que se refere ao agregado de sábados e domingos ao longo de um ano. Com isso, os 5 primeiros conjuntos carga-GD tem menor probabilidade de ocorrência. Alguns conjuntos, como por exemplo, o que envolve o cenário 2 da carga e o cenário 3 da GD, tem maior relevância entre os demais, representando pouco mais de 27% da probabilidade de ocorrência entre os 10 conjuntos gerados.

Uma comparação dos valores obtidos a partir da combinação de cenários representativos da carga e da GD, para distintos números de cenários, é apresentada na Tabela 10. São apresentados os resultados da energia de perdas anual do sistema

e da soma das violações nos limites de tensão (Z) no sistema de 23 nós para duas situações distintas. Os cenários da carga foram definidos com variação $\Delta = 0\%$ para que fosse possível analisar de maneira mais clara a influência da inserção das GDs e também com $\Delta = 70\%$, a qual é a variação definida para a geração das curvas de carga artificiais e cenários representativos nas simulações envolvendo o modelo de compensação de potência reativa da Seção 5.2.

Na Tabela 10, a coluna 1 apresenta a variação empregada sobre as curvas de carga (Δ). As colunas 2 e 3 apresentam a variação do número de \mathcal{K} cenários representativos gerados pelo *K-means* para a carga e para a GD, respectivamente. As colunas 4 a 7 apresentam os resultados obtidos a partir da combinação das curvas de carga horárias e das curvas de geração das GDs, com 24 valores. Já as colunas 8 a 11 apresentam os resultados da combinação das curvas de carga diárias e das curvas de geração das GDs sintetizadas por 8 patamares com 3 horas de duração cada. Os patamares representam a média a cada 3 horas dos valores gerados nas curvas de carga e nas curvas de geração horárias. Portanto, as colunas 4 e 5 e as colunas 8 e 9 apresentam a comparação dos valores da energia de perdas dos 365 dias gerados com o número de \mathcal{K} cenários, respectivamente. Já as colunas 6 e 7 e as colunas 10 e 11 apresentam a comparação entre a soma das violações dos limites de tensão dos panoramas com 365 dias e com \mathcal{K} cenários.

Pelo fato das curvas de carga representarem dias úteis, sábados e domingos, 3 cenários representativos da carga foram o suficiente para retratar um ano de operação quando considerado um delta de variação sobre as curvas de carga igual a zero, como representado pelas primeiras 15 linhas da Tabela 10. Pode-se observar uma grande proximidade entre os valores anuais obtidos, ao variar o número de cenários da GD, quando são considerados 2 ou mais cenários representativos da carga. Este fato ocorre devido a separação do agregado das curvas de carga artificiais de finais de semana em um ou mais cenários. Quando é considerado apenas uma curva de carga representativa, os dias úteis, sábados e domingos são representados por apenas um cenário, o que justifica a diferença significativa frente aos demais casos.

O incremento no número de cenários da GD permitiu obter valores muito próximos aos obtidos com os 365 dias de operação para $\Delta = 0\%$ e bons valores para $\Delta = 70\%$. Com apenas um cenário representativo da GD já é possível obter uma boa

Tabela 10: Comparação dos resultados obtidos através da combinação dos cenários representativos de curvas de carga e GDs através do *K-means* para curvas diárias com 24 valores e com 8 patamares.

Δ	Número de cenários (\mathcal{K})		Curva de carga/GD - 24 valores				Curva de carga/GD - 8 patamares de 3h				
			Perdas (MWh/ano)		Z (pu)		Perdas (MWh/ano)		Z (pu)		
	Carga	GD	365 dias	\mathcal{K} cenários	365 dias	\mathcal{K} cenários	365 dias	\mathcal{K} cenários	365 dias	\mathcal{K} cenários	
0%	1	1	495,45	413,48	0,0662	0,0253	479,75	400,32	0,0542	0,0136	
		2		414,72				0,0261		401,67	0,0152
		3		414,96				0,0261		401,72	0,0152
		5		415,51				0,0263		402,20	0,0153
		10		416,01				0,0265		402,64	0,0154
		100		416,69				0,0269		403,30	0,0157
		2		1				491,27		0,0642	475,91
	2			492,58				0,0652		477,09	0,0532
	3			492,77				0,0653		477,44	0,0533
	5			493,19				0,0654		477,82	0,0535
	10			493,76				0,0657		478,27	0,0538
	100			494,47				0,0660		478,92	0,0541
	3	1		491,90				0,0642		476,53	0,0523
		2		493,25				0,0652		477,70	0,0533
		3		493,36				0,0653		477,88	0,0533
		5		493,86				0,0655		478,10	0,0535
		10		494,35				0,0658		478,89	0,0538
		100		495,09				0,0661		479,52	0,0541
70%	1	1	508,61	414,21	0,0722	0,0259	484,49	401,05	0,0565	0,0142	
		2		415,44				0,0265		402,40	0,0156
		3		415,68				0,0265		402,45	0,0156
		5		416,23				0,0267		402,93	0,0157
		10		416,73				0,0270		403,37	0,0158
		100		417,41				0,0273		404,03	0,0161
		2		1				491,95		0,0644	476,49
	2			493,26				0,0655		477,67	0,0535
	3			493,45				0,0655		478,02	0,0536
	5			493,87				0,0656		478,41	0,0538
	10			494,43				0,0660		478,85	0,0540
	100			495,14				0,0663		479,50	0,0543
	3	1		492,07				0,0645		477,08	0,0526
		2		493,39				0,0653		477,90	0,0536
		3		493,76				0,0655		478,03	0,0536
		5		494,09				0,0658		478,42	0,0538
		10		494,55				0,0660		478,89	0,0540
		100		495,25				0,0663		479,57	0,0544

aproximação dos valores de energia de perdas. Entretanto, ao simular os cenários da carga com uma variação $\Delta = 70\%$ para 3 cenários representativos da carga com 24 valores, por exemplo, a diferença percentual entre os valores da energia de perdas para 365 dias e os κ cenários da GD, teve uma variação entre 3,3 e 2,6% frente a uma variação de 0,8 a 0,2% ao considerar as mesmas combinações para $\Delta = 0\%$.

Esta diferença é justificada pois há um aumento significativo da variabilidade entre as curvas de carga ao considerar uma variação $\Delta = 70\%$, e com isso, 3 cenários representativos da carga geram um aproximação inferior frente a uma variação $\Delta = 0\%$, o que necessitaria de mais cenários representativos, no entanto acarretaria em um aumento do esforço computacional.

O tempo de simulação, para os diferentes casos analisados na Tabela 10 para $\Delta = 0\%$, variou entre 7,5 e 12 segundos, na qual é considerada uma linha da Tabela 10, que gera cenários tanto para as curvas de carga artificiais com 24 valores, quanto para as curvas com 8 patamares de 3 horas de duração. Ao considerar apenas a geração dos cenários com 24 valores, o tempo de simulação variou entre 5,5 e 10 segundos. Já para as simulações envolvendo os cenários da carga com uma variação $\Delta = 70\%$, o tempo de simulação variou em 8,5 e 14 segundos.

Com o objetivo de avaliar o modelo considerando uma variação expressiva no comportamento da carga, foi adotado $\Delta = 70\%$ para a elaboração das curvas de carga artificiais destes cenários. A partir das simulações e análises realizadas para diferentes valores e combinações de cenários representativos, foi definido como valor aceitável a energia de perdas para os cenários que tiverem uma aproximação mínima de 95% frente ao valor exato dos 365 dias, bem como, uma aproximação mínima de 90% para o valor do somatório das violações de tensão. Com isso, para que ocorra um bom compromisso entre o desempenho do modelo proposto e o tempo de simulação, mostrou-se suficiente a utilização de 3 cenários representativos da carga e 3 cenários representativos da GD para as simulações do modelo de compensação de potência reativa.

5.2 Modelo de compensação de potência reativa

Nesta seção são apresentados os resultados dos testes realizados para validar o modelo de otimização proposto. Para tanto, foi utilizado o sistema de distribuição de

23 nós, descrito na Seção 5.1.1, considerando curvas de carga geradas artificialmente e GDs fotovoltaicas. São comparados os resultados obtidos pelo modelo com base nos cenários representativos frente aos resultados obtidos com 365 dias diferentes de operação.

Em todos os testes que são apresentados a seguir, são adotados os valores de 3% para o DRP e 0,5% para o DRC. No entanto, diferentemente do que é estabelecido pela ANEEL, foi assumido que o custo da compensação é imediato. O valor da tarifa de uso do sistema de distribuição (TUSD) é igual a 0,05 \$/kWh, valor próximo ao atualmente praticado pela Companhia Estadual de Distribuição de Energia Elétrica (CEEE-D) em Porto Alegre para consumidores de baixa tensão. O custo da energia é igual a a 0,11 \$/kWh (RESENER et al., 2016).

O horizonte de planejamento para o modelo proposto é de 3 anos, considerando uma taxa de juros anual de 10%. Com relação aos BCs disponíveis para a instalação, foram considerados quatro tipos: dois fixos e dois automáticos. A Tabela 11 apresenta a potência nominal e os custos de aquisição, instalação e manutenção dos BCs considerados, conforme o trabalho de Resener (2016).

Tabela 11: Dados dos bancos de capacitores.

Tipo	Potência Nominal [kvar]	Custo de Aquisição [\$]	Custo de Instalação [\$]	Custo de Manutenção [\$/ano]
F600	600	6.500,00	530,97	341,30
F1200	1200	9.000,00	530,97	397,92
A600	0 ou 600	8.500,00	796,46	968,89
A1200	0 ou 1200	11.450,00	796,46	1.022,78

Fonte: Adaptado de Resener (2016).

Conforme as restrições definidas na Seção 3.2.2, os BCs automáticos podem estar ligados ou desligados, limitados a ligar apenas uma vez ao dia. Nos testes de validação do modelo de alocação de BCs, foi considerado que estão disponíveis para instalação até 3 BCs de cada tipo da Tabela 11 e foi definido um limite de instalação de 3 BCs no alimentador, considerando todos os tipos disponíveis.

Tendo como base este limite definido para a instalação de BCs fixos e automáticos, é possível definir o espaço de busca do problema, a partir das equações (22) e (23). Nos testes realizados, são considerados 3 cenários de operação para os casos

sem GD e 9 cenários de operação para os casos com a presença de GDs. Com isso, o espaço de busca para os casos analisados nesta Seção, é de aproximadamente até $4,15 \times 10^{20}$ soluções candidatas para os casos sem GD e de até $5,83 \times 10^{42}$ soluções candidatas para os casos com GD.

Previamente à otimização e a determinação da alocação ótima dos BCs, é analisado o caso base do sistema de 23 nós, no qual não há nenhum BC instalado. O objetivo desta análise é identificar o perfil de tensão, as perdas e o custo de operação da rede antes da compensação de potência reativa. A Tabela 12 apresenta a solução do caso base sem GD para 3 cenários representativos e para os 365 dias do ano. São apresentados a soma das violações anuais nos níveis de tensão (Z), calculada a partir da equação (20), as perdas anuais de energia e os custos de operação resultantes, segmentado entre o custo das violações de tensão e o custo das perdas.

Tabela 12: Resultados do caso base do sistema de 23 barras sem GD.

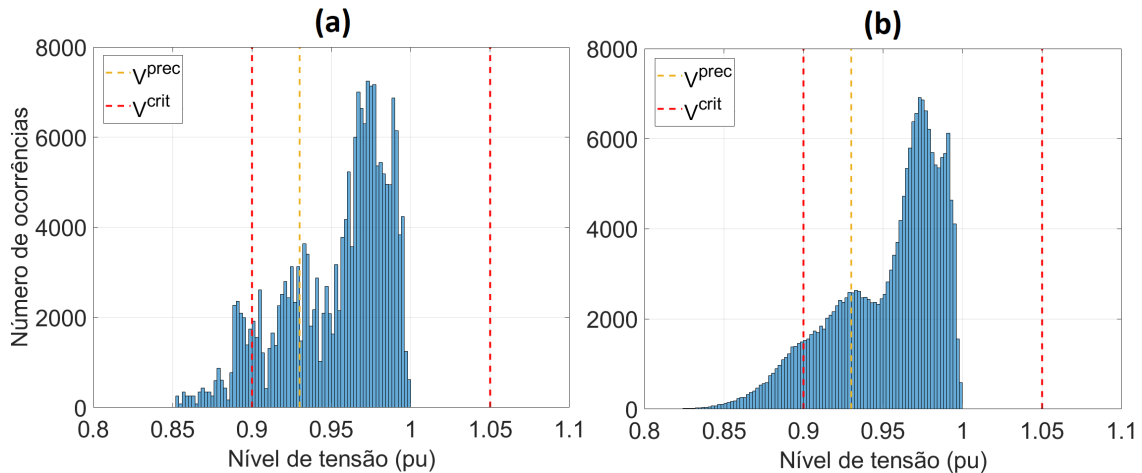
Resultados	3 Cenários	365 dias	Diferença [%]
Z [pu]	0,1385	0,1428	3,01
Perdas [MWh/ano]	688,91	702,17	1,89
C^{viol} [$\times 10^3$ \$]	982,71	797,42	23,23
C^{perdas} [$\times 10^3$ \$]	207,30	211,29	1,89
C^{total} [$\times 10^3$ \$]	1190,01	1008,71	17,97

A partir da Tabela 12, pode-se verificar a proximidade dos resultados obtidos para 3 cenários representativos frente a 365 dias de operação, conforme já validado na Tabela 5. Houve uma diferença significativa apenas entre os custos totais devido as elevadas violações de tensão presentes no caso base do sistema de 23 nós.

A Figura 28 apresenta os histogramas do perfil de tensão anual do sistema de 23 nós para o caso base sem GDs e com 3 cenários, à esquerda e com 365 dias distintos de operação, à direita. A medição dos níveis de tensão é horária e em cada nó (exceto a subestação) para 8760 horas, totalizando 192720 ocorrências. A coordenada vertical representa o número de ocorrências e a coordenada horizontal representa o nível de tensão em pu. As linhas tracejadas em amarelo representam o limite do nível de tensão precária, entre 0,9 e 0,93 pu. Já as linhas tracejadas vermelhas representam os limites do nível de tensão crítica, os quais ocorrem para tensões acima de 1,05 pu e abaixo de 0,9 pu para o nível de tensão do sistema adotado, que é de 13,8 kV. A partir

da Figura 28, pode-se perceber que o histograma à esquerda, por representar valores operacionais médios através dos cenários representativos, tem algumas diferenças frente ao histograma dos 365 dias do ano, contudo o formato dos histogramas são semelhantes.

Figura 28: Histograma do perfil de tensão para o caso base sem GD, para: (a) 3 cenários e (b) 365 dias.



Fonte: Elaborada pelo autor.

De forma análoga, a Tabela 13 apresenta a solução do caso base, porém com a presença de GDs fotovoltaicas, para 9 cenários representativos e para os 365 dias do ano. As GDs foram alocadas nos nós 8, 16 e 20, conforme descrito na Seção 5.1.3.

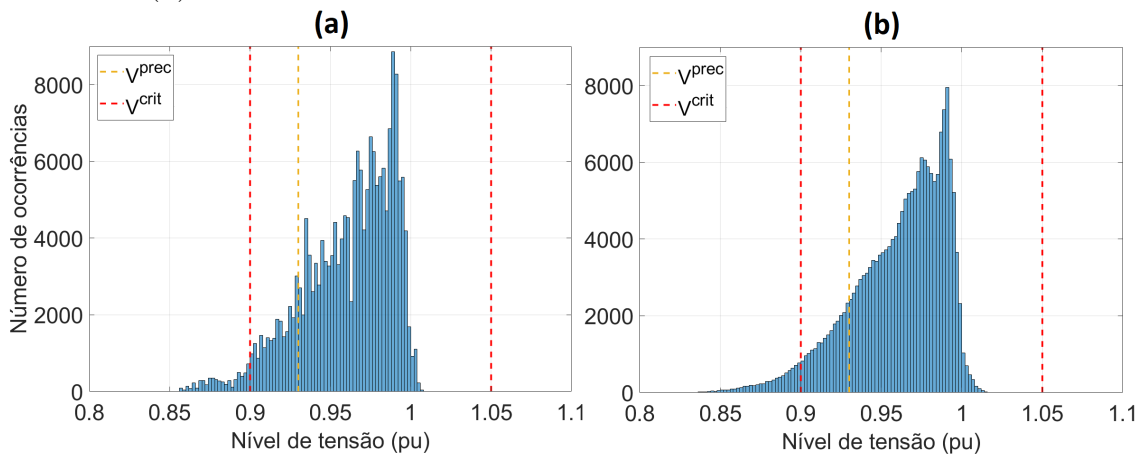
Tabela 13: Resultados do caso base do sistema de 23 nós com GD.

Resultados	9 Cenários	365 dias	Diferença [%]
Z [pu]	0,0655	0,0722	9,28
Perdas [MWh/ano]	493,76	508,61	2,92
C^{viol} [$\times 10^3$ \$]	485,94	412,51	17,80
C^{perdas} [$\times 10^3$ \$]	148,82	153,05	2,76
C^{total} [$\times 10^3$ \$]	634,76	565,56	12,23

A Figura 29 apresenta os histogramas do perfil de tensão anual do sistema de 23 nós para o caso base com a inclusão de GDs para 9 cenários, à esquerda e para 365 dias de operação, à direita. A partir da Tabela 13 e da Figura 29, pode-se perceber uma melhoria significativa em todos os resultados analisados a partir da inclusão de GDs, com redução acentuada no custo das perdas ($-28,2\%$), das violações dos níveis de tensão ($-50,5\%$) e custo total ($-46,7\%$).

É importante ressaltar que, mesmo sendo um sistema com pequenas dimensões, a distribuição uniforme da carga torna o problema de otimização mais difícil de ser resolvido. Somado a isso, o sistema de 23 nós possui elevada carga e apresenta tensões muito baixas no seu caso base, como pode ser visualizado pelas Figuras 28 e 29.

Figura 29: Histograma do perfil de tensão para o caso base com GD, para: (a) 9 cenários e (b) 365 dias.



Fonte: Elaborada pelo autor.

O modelo de compensação de potência reativa proposto foi resolvido através do AG, no qual foram utilizados os parâmetros mostrados na Tabela 14. Os parâmetros do AG foram testados e validados, mostrando-se adequados para a realização dos testes. Com isso, salvo quando dito o contrário, os resultados gerados nesta Seção são obtidos a partir dos parâmetros da Tabela 14.

O problema da alocação ótima de BCs foi resolvido considerando que todos os nós são candidatos a receber um BC, exceto o nó da subestação, o que totaliza 22 nós candidatos. Os resultados são apresentados conforme segue, sendo que as colunas indicadas nas tabelas pelo número de cenários e por 365 dias, representam os resultados obtidos através da operação do sistema considerando dias representativos (cenários) e os 365 dias diferentes no ano. O nó onde o capacitor deve ser instalado é indicado pelo símbolo "@" e o modo de operação representa o horário diário de funcionamento dos capacitores automáticos para cada cenário representativo (K).

Inicialmente, as parcelas da função objetivo são analisadas de maneira independente, considerando apenas a parcela referente às perdas de energia ou apenas a parcela referente às violações dos níveis de tensão. Na sequência, as duas parcelas

Tabela 14: Parâmetros adotados no AG.

Parâmetro	Valor
Número de Gerações (n_{ger})	200
Número de Indivíduos (n_{pop})	200
População Inicial (n_{init})	5 n_{pop}
Taxa de Recombinação (t_{rec})	50%
Taxa de Mutação (t_{mut})	30% (inicial) - 40% (final)
Indivíduos na Elite (n_{eli})	3
Participantes do Torneio (n_{tor})	3
Distância mínima - Elite (d_{eli}^{min})	3 (inicial) - 2 (final)
Distância mínima - População (d_{pop}^{min})	5 (inicial) - 1 (final)
Distância mínima - Pop. Inicial (d_{init}^{min})	10

da função objetivo são analisadas. Para cada parcela são analisadas duas situações, considerando a ausência ou a inclusão de GDs.

5.2.1 Alocação de BCs - Apenas Perdas

Primeiramente, é realizada uma análise dos resultados obtidos considerando apenas a parcela das perdas no custo de operação do sistema; o custo das violações de tensão é desconsiderado nesta análise.

5.2.1.1 Sistema de 23 nós sem GD

A Tabela 15 apresenta a melhor solução para o problema da alocação de BCs obtida pelo AG no sistema de 23 nós sem GD, utilizando os parâmetros descritos pela Tabela 14. As primeiras linhas apresentam os BCs alocados no sistema, bem como o modo de operação horário para os diferentes cenários quando são alocados capacitores automáticos. A seguir são mostrados os custos de investimento e manutenção dos BCs alocados. Por último, é apresentada a comparação dos resultados obtidos para 3 cenários representativos e para os 365 dias diferentes de operação. São apresentados a soma das violações nos níveis de tensão (Z), as perdas anuais de energia e os custos de operação resultantes, segmentado entre o custo das violações de tensão e o custo das perdas. Nesta avaliação é apenas considerado o custo das perdas.

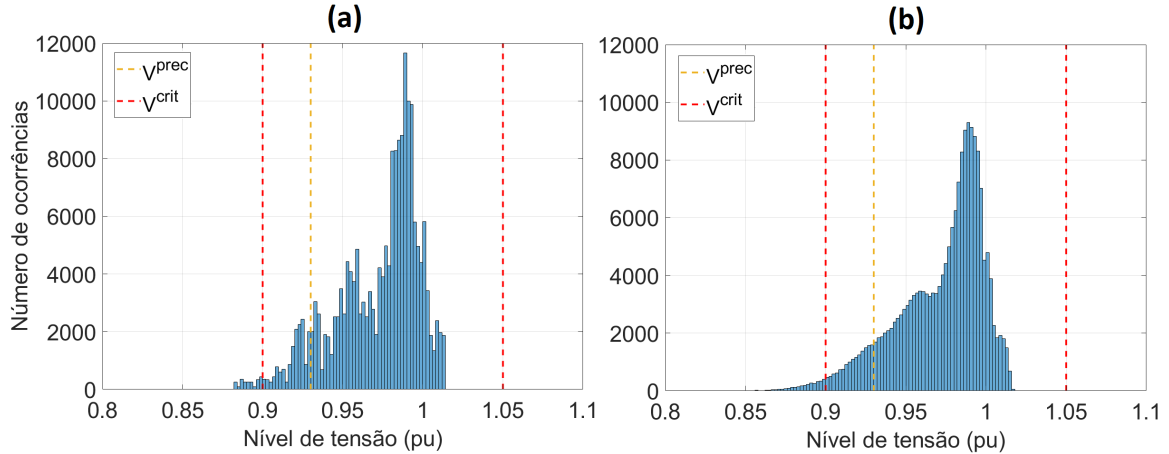
Tabela 15: Resultados da alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo.

Resultados		Melhor Solução obtida																								
Posição		Modo de Operação																								
F600 @10		—																								
		<i>K</i>	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
A600 @16		1								x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
		2								x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
		3																								
C^{inv} [x10 ³ \$]																								16,33		
C^{manut} [x10 ³ \$]																								3,59		
		3 Cenários												365 dias												
Z [pu]		0,0286												0,0350												
Perdas [MWh/ano]		539,65												552,98												
C^{viol} [x10 ³ \$]		—												—												
C^{perdas} [x10 ³ \$]		162,38												166,39												
C^{total} [x10 ³ \$]		182,30												186,31												

De acordo com a Tabela 15, a melhor solução indica a instalação de um capacitor fixo de 600 kvar no nó 10 e um capacitor automático de 600 kvar no nó 16, o qual deve estar ligado diariamente entre 9h e 23h para os Cenários 1 e 2, mas permanecendo desligado para o Cenário 3, que representa os dias de menor consumo (finais de semana). Comparando com o caso base sem GD, as perdas anuais de energia foram reduzidas para 539,65 MWh/ano (cerca de 78,3% do valor inicial). As violações dos limites de tensão também foram reduzidas e a soma representa cerca de 20,6% do valor inicial. Cabe ressaltar a proximidade entre os resultados obtidos pelos dois métodos; por exemplo, para a melhor solução obtida, a diferença entre os custos totais obtidos na solução através de 3 cenários representativos e a solução com 365 dias diferentes, é de apenas -2,15%, tomando como base o valor dos 365 dias.

A Figura 30 apresenta os histogramas do perfil de tensão anual da melhor solução para o problema da alocação de BCs obtida pelo AG no sistema de 23 nós sem GD. À esquerda está representado o histograma para 3 cenários representativos e à direita para 365 dias diferentes de operação.

Figura 30: Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo, para: (a) 3 cenários e (b) 365 dias.

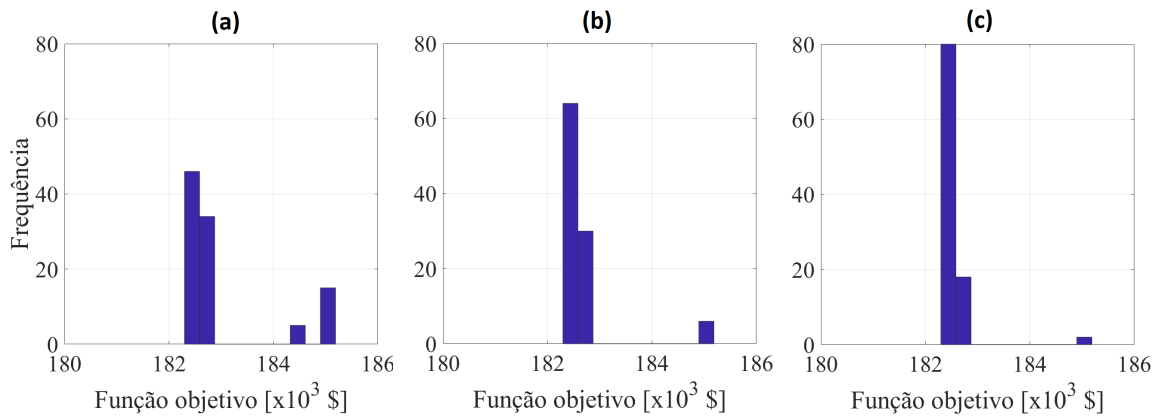


Fonte: Elaborada pelo autor.

A partir da Figura 30, pode-se perceber que o histograma à esquerda, por representar valores operacionais médios através dos cenários representativos, tem algumas diferenças frente ao histograma dos 365 dias do ano, contudo o perfil do número de ocorrências tem grande similaridade. Cabe ressaltar também a melhoria dos níveis de tensão frente ao caso base da Figura 28, a partir da alocação dos BCs – ainda que tenha sido desconsiderado o custo das violações de tensão na função objetivo.

De forma a realizar uma análise de sensibilidade da população adotada nos parâmetros do AG da Tabela 14, aplicada a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo, são apresentados na Figura 31 os histogramas das melhores soluções obtidas em 100 execuções do AG com os parâmetros da Tabela 14, mas variando a população de 50 a 200 indivíduos. Pode-se verificar que com o incremento do número de indivíduos, é realizada uma maior varredura no espaço de busca do problema, o que propicia a obtenção de soluções mais próximas da melhor solução obtida. Ao considerar 200 indivíduos, na Figura 31(c), 80% das soluções convergiram para esta solução. O tempo de simulação variou entre 736 segundos para uma população de 50 indivíduos a 2030 segundos para uma população de 200 indivíduos. Por esta razão, foi adotado o valor de 200 indivíduos para os demais resultados deste capítulo, devido ao bom compromisso entre a qualidade dos resultados e o tempo despendido na simulação.

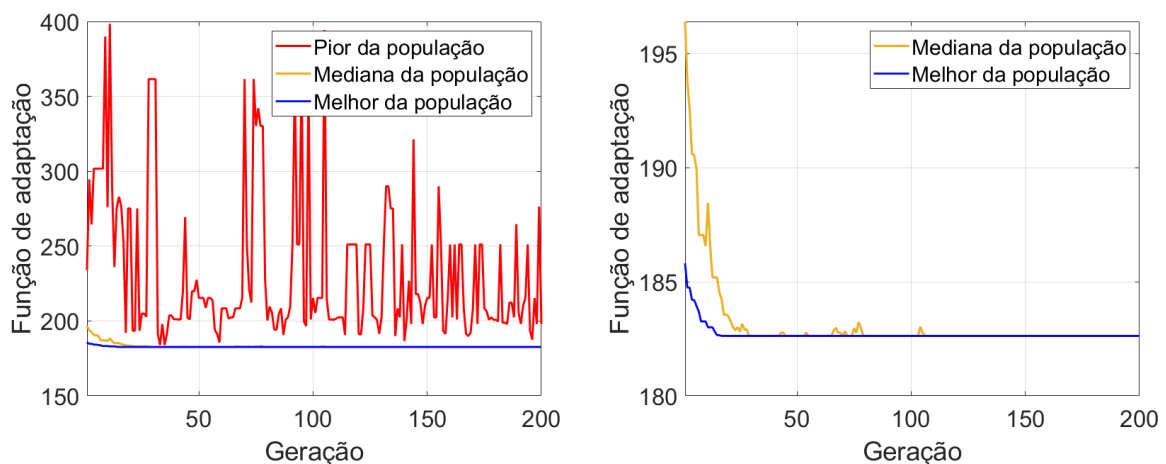
Figura 31: Histograma de 100 execuções da função objetivo no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo para amostras de população com: (a) 50, (b) 100 e (c) 200 indivíduos.



Fonte: Elaborada pelo autor.

De maneira semelhante, as Figuras 32 e 33 visam realizar uma análise de sensibilidade no número de gerações do AG adotado pela Tabela 14. A Figura 32 demonstra a trajetória do pior, da mediana e do melhor indivíduo da população ao longo de 200 gerações para uma execução do AG. No gráfico à esquerda, estão representados o pior indivíduo da população em vermelho, a mediana em amarelo e a solução incumbente em azul, já no gráfico à direita são representados apenas a mediana e a solução incumbente, mas com maior resolução no valor da função de adaptação.

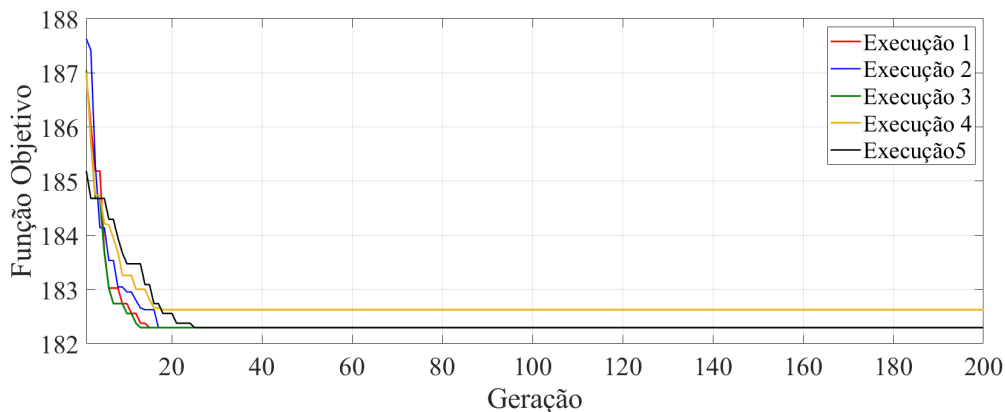
Figura 32: Convergência da função objetivo para a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo.



Fonte: Elaborada pelo autor.

A Figura 33 ilustra a trajetória de convergência da solução incumbente de 5 execuções do AG. Nesta Figura, observa-se que 80% das execuções atingiram o patamar da melhor solução obtida em menos de 30 gerações, o que exalta a rápida convergência do algoritmo proposto para a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo. Apenas a execução 4 convergiu para um mínimo local, mas com grande proximidade da melhor solução.

Figura 33: Convergência de 5 execuções da função objetivo para a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de perdas da função objetivo.



Fonte: Elaborada pelo autor.

Entretanto, a Seção 5.2.1 apresenta os resultados para apenas uma parcela da função objetivo, o que acarreta uma menor complexidade na obtenção da melhor solução. Na Seção 5.2.3, é avaliada a função objetivo completa (perdas e violações de tensão), o que aumenta a complexidade do problema e requer mais gerações para a convergência da solução incumbente. Por este motivo, foi adotado o valor de 200 gerações para os testes realizados neste capítulo, número suficiente para resolver todos os casos com qualidade.

5.2.1.2 Sistema de 23 nós com GD

Na Tabela 16, é apresentada a melhor solução para o problema da alocação de BCs obtida pelo AG no sistema de 23 nós considerando a inclusão de GDs. Nesta avaliação, também é considerado apenas o custo das perdas. Na Tabela 16, a melhor solução indica a instalação de apenas um capacitor fixo de 600 kvar no nó 10. Comparando com o caso base com GD, as perdas anuais de energia foram reduzidas para 424,21 MWh/ano (o que representa cerca de 85,9% do valor inicial). As violações dos limites de tensão também foram reduzidas e a soma representa cerca de 36%

do valor inicial. Como consequência, obteve-se uma redução de aproximadamente 78,6% nos custos totais para esta análise, a qual desconsidera o custo das violações de tensão na função objetivo. A diferença entre os resultados obtidos para a melhor solução através de 9 cenários e avaliada para 365 dias diferentes, é de apenas -3,02%, tomando como base o valor dos 365 dias. Comparando com os resultados da Seção 5.2.1.1, onde há a alocação dos BCs mas sem a inclusão de GDs, as perdas anuais tiveram uma redução de 21,4% e os custos totais obtiveram uma redução de 25,6%, o que confirma os benefícios da inclusão de GDs no sistema de distribuição.


Tabela 16: Resultados da alocação de BCs no sistema de 23 nós com GD considerando a parcela de perdas da função objetivo.

Resultados	Melhor Solução obtida	
Posição	Modo de Operação	
F600 @10	—	
C^{inv} [x10 ³ \$]	7,03	
C^{manut} [x10 ³ \$]	0,93	
	9 Cenários	365 dias
Z [pu]	0,0236	0,0288
Perdas [MWh/ano]	424,21	438,25
C^{viol} [x10 ³ \$]	—	—
C^{perdas} [x10 ³ \$]	127,65	131,88
C^{total} [x10 ³ \$]	135,61	139,84

A Figura 34 apresenta os histogramas do perfil de tensão anual da melhor solução para o problema da alocação de BCs no sistema de 23 nós sem GD. À esquerda está representado o histograma para 9 cenários representativos e à direita para 365 dias diferentes de operação.

Ao comparar o histograma da Figura 34 com os resultados da Figura 30 sem GDs alocadas, nota-se um incremento nos níveis de tensão, propiciados pela inclusão das GDs, o que melhora os níveis de tensão principalmente no intervalo de violação de tensão precárias. Cabe ressaltar também a melhoria dos níveis de tensão frente ao caso base da Figura 29, a partir da alocação dos BCs – ainda que tenha sido desconsiderado o custo das violações de tensão na função objetivo.

Figura 34: Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós com GD considerando a parcela de perdas da função objetivo, para: (a) 9 cenários e (b) 365 dias.



Fonte: Elaborada pelo autor.

A convergência da função objetivo ocorreu de maneira similar ao caso sem a inclusão de GDs, tendo uma convergência rápida, com a convergência da solução incumbente antes da geração 25 para os testes realizados. Com relação ao esforço computacional, cada execução do modelo proposto foi resolvido em torno de 5250 segundos considerando os dados do AG da Tabela 14. Houve um maior esforço computacional frente ao caso sem GD, da Seção 5.2.1.1, devido ao incremento no número de cenários, dada a necessidade da utilização de cenários combinatórios de carga-GD para a solução do problema.

5.2.2 Alocação de BCs - Apenas Violações de Tensão

Nesta Seção, é realizada uma análise dos resultados obtidos considerando apenas a parcela das violações de tensão no custo de operação do sistema; o custo das perdas é desconsiderado nesta análise.

5.2.2.1 Sistema de 23 nós sem GD

A Tabela 17 apresenta a melhor solução para o problema da alocação de BCs obtida pelo AG no sistema de 23 nós sem GD, utilizando os parâmetros descritos pela Tabela 14.

Na Tabela 17, a melhor solução indica a instalação de um capacitor fixo de


1200 kvar no nó 19 e um capacitor automático de 1200 kvar no nó 22, o qual deve estar ligado diariamente entre 9h e 21h para os Cenários 1 e 2, mas permanecendo desligado para o Cenário 3. Comparando com o caso base sem GD, as perdas anuais de energia aumentaram para 924,48 MWh/ano, fato justificado pela não consideração do custo das perdas na função objetivo, o que prioriza a redução das violações de tensão independente do valor de perdas obtido. A soma das violações dos limites de tensão foi reduzida para um valor praticamente nulo. Como consequência, obteve-se uma redução acentuada nos custos totais para esta análise frente ao caso base sem GD, pois a melhor solução contabilizou apenas custos de investimento e manutenção dos BCs, devido a não consideração do custo relativo às perdas de energia e por ter propiciado a redução a um valor praticamente nulo para as violações de tensão. No entanto, houve uma pequena diferença entre os custos totais obtidos na solução por intermédio de 3 cenários e a solução com 365 dias diferentes, visto que houve um maior custo de violações de tensão para a solução de 365 dias. Este custo não foi observado na solução por cenários representativos devido a suavização dos valores extremos por valores médios através dos cenários.

Tabela 17: Resultados da alocação de BCs no sistema de 23 nós sem GD considerando a parcela de violações de tensão da função objetivo.

Resultados		Melhor Solução obtida																								
Posição		Modo de Operação																								
F1200 @19		-																								
		<i>K</i>	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24
A1200 @22		1								x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
		2								x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x
		3																								
C^{inv} [x10 ³ \$]																								21,78		
C^{manut} [x10 ³ \$]																								3,89		
		3 Cenários												365 dias												
Z [pu]		0,0001												0,0024												
Perdas [MWh/ano]		924,48												938,18												
C^{viol} [x10 ³ \$]		0,00												7,50												
C^{perdas} [x10 ³ \$]		-												-												
C^{total} [x10 ³ \$]		25,66												33,17												

A Figura 35 apresenta os histogramas do perfil de tensão anual da melhor solução para o problema da alocação de BCs obtida pelo AG no sistema de 23 nós sem GD. À esquerda está representado o histograma para 3 cenários representativos e à direita para 365 dias diferentes de operação. Pode-se perceber que o histograma à esquerda, por representar valores das tensões através dos cenários médios representativos, tem algumas diferenças frente ao histograma dos 365 dias do ano, contudo o perfil do número de ocorrências tem grande similaridade. Cabe ressaltar também a melhoria dos níveis de tensão frente ao caso base da Figura 28, a partir da alocação dos BCs. Pode-se observar também que praticamente todas as ocorrências ficaram dentro dos níveis adequados de tensão devido a consideração apenas das penalidades sobre as violações de tensão na função objetivo.

Figura 35: Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós sem GD considerando a parcela de violações de tensão da função objetivo, para: (a) 3 cenários e (b) 365 dias.



Fonte: Elaborada pelo autor.

A convergência da função objetivo ocorreu com menos de 15 gerações para diferentes execuções do AG, o que demonstra a rápida convergência do algoritmo para a alocação dos BCs considerando apenas a parcela de violações de tensão da função objetivo. Com relação ao esforço computacional, cada execução do modelo proposto foi resolvido em torno de 2150 segundos, considerando os dados do AG da Tabela 14.

5.2.2.2 Sistema de 23 nós com GD

A Tabela 18 apresenta a melhor solução para o problema da alocação de BCs no sistema de 23 nós considerando a inclusão de GDs.

Tabela 18: Resultados da alocação de BCs no sistema de 23 nós com GD considerando a parcela de violações de tensão da função objetivo.

Resultados		Melhor Solução obtida																									
Posição		Modo de Operação																									
F1200 @9		-																									
		K	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	
A1200 @21	1										x	x	x	x	x	x	x	x	x	x	x	x					
	1 2										x	x	x	x	x	x	x	x	x	x	x	x	x				
	3										x	x	x	x	x	x	x	x	x	x	x	x	x				
	1										x	x	x	x	x	x	x	x	x	x	x	x	x	x			x
	2 2										x	x	x	x	x	x	x	x	x	x	x	x	x	x	x		x
	3										x	x	x	x	x	x	x	x	x	x	x	x	x	x	x		x
	1																										
	3 2																										
	3																										
	C^{inv} [x10 ³ \$]														21,78												
	C^{manut} [x10 ³ \$]														3,89												
			9 Cenários												365 dias												
Z [pu]		0,0000												0,0011													
Perdas [MWh/ano]		670,23												684,74													
C^{viol} [x10 ³ \$]		0,00												0,00													
C^{perdas} [x10 ³ \$]		-												-													
C^{total} [x10 ³ \$]		25,66												25,66													

Na Tabela 18, a melhor solução indica a instalação de um capacitor fixo de 1200 kvar no nó 9 e um capacitor automático de 1200 kvar no nó 21, o qual deve estar ligado diariamente entre 9h e 20h para o Cenário 1 da carga e os Cenários 1, 2 e 3 da GD, e entre 9h e 21h para o Cenário 2 da carga e os Cenários 1, 2 e 3 da GD. O capacitor automático permanece desligado para o Cenário 3 da carga e todos os Cenários da GD, provavelmente por representar os dias de final de semana, com menor demanda. Comparando com o caso base com GD, as perdas anuais de energia aumentaram para 670,23 MWh/ano, fato que da mesma forma é justificado pela não consideração do custo das perdas na função objetivo, o que prioriza a redução das violações de tensão independente do valor de perdas obtido. A soma


das violações dos limites de tensão foi reduzida para um valor praticamente nulo. Como consequência, obteve-se uma redução acentuada nos custos totais para esta análise frente ao caso base com GD, pois a melhor solução contabilizou apenas custos de investimento e manutenção dos BCs, devido a não consideração do custo relativo as perdas de energia e por ter propiciado a redução a um valor praticamente nulo para as violações de tensão.

Diferentemente dos resultados da Seção 5.2.2.1, não houve diferença entre os custos totais obtidos na solução por intermédio de 9 cenários e a solução com 365 dias, visto que na solução por 365 dias também não houve penalização por violações nos níveis de tensão, pois as violações ficaram abaixo dos limites percentuais permitidos.

Comparando também com os resultados da Seção 5.2.2.1, onde há a alocação de BCs mas sem a inclusão de GDs, as perdas anuais tiveram uma redução de 27,5%. Entretanto, o custo total permaneceu idêntico, visto que os mesmos tipos de BCs foram instalados e portanto o custo de instalação e manutenção foi o mesmo, apenas o modo de operação e a alocação diferiu.

A Figura 36 apresenta os histogramas do perfil de tensão anual da melhor solução para o problema da alocação de BCs no sistema de 23 nós com a inclusão de GDs. À esquerda está representado o histograma para 3 cenários representativos e à direita para 365 dias diferentes de operação.

Figura 36: Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós com GD considerando a parcela de violações de tensão da função objetivo, para: (a) 9 cenários e (b) 365 dias.



Fonte: Elaborada pelo autor.

A partir da Figura 36, cabe ressaltar a melhoria dos níveis de tensão frente ao caso base da Figura 29, devido à alocação dos BCs. Pode-se observar também que praticamente todas as ocorrências ficaram dentro dos níveis adequados de tensão devido a consideração apenas das penalidades sobre as violações de tensão na função objetivo. Na comparação com a Figura 35, pode-se perceber que a presença de GDs elevou os níveis de tensão, deslocando o histograma levemente no sentido do aumento dos níveis de tensão.

A convergência da função objetivo ocorreu com menos de 15 gerações para diferentes execuções do AG. Com relação ao esforço computacional, dada a necessidade da utilização de cenários combinatórios de carga-GD para a solução do problema, cada execução do modelo proposto foi resolvido em torno de 5800 segundos considerando os dados do AG da Tabela 14.

5.2.3 Alocação de BCs - Função Objetivo completa

Nesta Seção, é realizada uma análise da função objetivo completa, sendo incluída tanto a parcela das perdas de energia quanto a parcela das violações de tensão no custo de operação do sistema.

5.2.3.1 Sistema de 23 nós com GD

A Tabela 19 apresenta a melhor solução para o problema da alocação de BCs obtida pelo AG no sistema de 23 nós considerando a inclusão de GDs. A solução indica a instalação de um BC fixo de 600 kvar no nó 13 e dois BCs automáticos, um de 600 kvar no nó 20 e um de 600 kvar no nó 23. O BC alocado no nó 20 deve estar ligado diariamente entre 8h e 19h, para o Cenário 1 da carga e o Cenário 1 da GD, e entre 8h e 20h, para o Cenário 1 da carga e os Cenários 2 e 3 da GD, e o Cenário 2 da carga e os Cenários 1, 2 e 3 da GD. O BC de 600 kvar do nó 23 deve estar ligado entre 18h e 23h para os Cenários 1 e 2 da carga e os Cenários 1, 2 e 3 da GD. Ambos capacitores automáticos permanecem desligados no Cenário 3 da carga, independentemente dos cenários da GD, por representar os dias de final de semana, com menor demanda.

Comparando com o caso base com GD, as perdas anuais de energia tiveram uma redução de 20,95% e as violações dos limites de tensão foram reduzidas para valores muito baixos, o que acarretou um custo de violações de tensão de apenas $0,66 \times 10^3$ \$

Tabela 19: Resultados da alocação de BCs no sistema de 23 nós com GD considerando as duas parcelas da função objetivo.


Resultados		Melhor solução obtida																									
Posição		Modo de Operação																									
F600 @13		-																									
A600 @20	K	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24		
	1								x	x	x	x	x	x	x	x	x	x	x	x							
	1 2								x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x		
	3								x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x		
	1								x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x		
	2 2								x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x		
	3								x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x	x		
	1																										
	3 2																										
	3																										
	A600 @23	1																			x	x	x	x	x	x	
		1 2																			x	x	x	x	x	x	
3																				x	x	x	x	x	x		
1																				x	x	x	x	x	x		
2 2																				x	x	x	x	x	x		
3																				x	x	x	x	x	x		
1																											
3 2																											
3																											
C^{inv} [$\times 10^3$ \$]														25,62													
C^{manut} [$\times 10^3$ \$]														6,23													
		9 Cenários												365 dias													
Z [pu]		0,0019												0,0060													
Perdas [MWh/ano]		390,26												404,39													
C^{viol} [$\times 10^3$ \$]		0,66												15,77													
C^{perdas} [$\times 10^3$ \$]		117,43												121,68													
C^{total} [$\times 10^3$ \$]		149,95												169,30													

frente ao valor do caso base de $485,94 \times 10^3$ \$. Como consequência, obteve-se uma redução acentuada de 76,38% nos custos totais para esta análise frente ao caso base com GD, mesmo com a contabilização dos custos de investimento e operação dos BCs nesta avaliação. A diferença entre os resultados obtidos para a solução através

de 9 cenários e solução para 365 dias no que se refere aos custos totais, foi de -11,43%, tomando como base o valor dos 365 dias, no qual houve uma maior diferença apenas no custo relacionado às violações dos níveis de tensão.

A Figura 37 apresenta os histogramas do perfil de tensão anual da melhor solução para o problema da alocação de BCs obtida pelo AG no sistema de 23 nós com a inclusão de GDs. À esquerda está representado o histograma para 9 cenários representativos e à direita para 365 dias diferentes de operação. Pode-se perceber que o histograma à esquerda, por representar valores operacionais médios através dos cenários representativos, tem algumas diferenças frente ao histograma dos 365 dias do ano, contudo o perfil do número de ocorrências tem grande similaridade. Cabe ressaltar também a melhoria dos níveis de tensão frente ao caso base da Figura 29, a partir da alocação dos BCs.

Figura 37: Histograma do perfil de tensão para a alocação de BCs no sistema de 23 nós com GD considerando as duas parcelas da função objetivo, para: (a) 9 cenários e (b) 365 dias.




Fonte: Elaborada pelo autor.

Pode-se observar que apenas algumas ocorrências ficaram fora dos níveis adequados de tensão, o que acarretou um custo mínimo de violações de tensão para os cenários representativos, mas um pequeno custo de violações para o caso que representa a operação dos 365 dias.

De forma a realizar uma análise de sensibilidade da população adotada nos parâmetros do AG da Tabela 14, aplicada a alocação de BCs no sistema de 23 nós com GD, mas desta vez considerando as duas parcelas da função objetivo, são apresen-

tados na Figura 38 os histogramas das melhores soluções obtidas em 100 execuções do AG com os parâmetros da Tabela 14, mas variando a população de 50 a 200 indivíduos.

Figura 38: Histograma de 100 execuções da função objetivo no sistema de 23 nós com GD considerando as duas parcelas da função objetivo para amostras de população com: (a) 50, (b) 100 e (c) 200 indivíduos.




Fonte: Elaborada pelo autor.

A partir da Figura 38, pode-se verificar que com o incremento no número de indivíduos, é realizada uma maior varredura no espaço de busca do problema, o que propicia a obtenção de soluções mais próximas da melhor solução obtida. A consideração das duas parcelas da função objetivo também aumentou consideravelmente o número de soluções boas com valores muito próximos a melhor solução obtida. Ao considerar 200 indivíduos, na Figura 38(c), há uma maior concentração das soluções nas proximidades da melhor solução obtida, com uma diferença de menos de 4% entre a pior e a melhor solução obtida pelas 100 execuções do AG. No entanto, ao considerar as duas parcelas da função objetivo, há uma maior complexidade e o aumento das não-convexidades, pois as duas parcelas são conflitantes entre si. Por esse fato, 5% das execuções atingiram o patamar da melhor solução obtida. O tempo de simulação variou entre aproximadamente 2690 segundos para uma população de 50 indivíduos a 6100 segundos para uma população de 200 indivíduos.

De maneira semelhante, as Figuras 39 e 40 visam realizar uma análise de sensibilidade no número de gerações do AG adotado pela Tabela 14, a partir da consideração das duas parcelas da função objetivo. A Figura 39 demonstra a trajetória do pior, da mediana e do melhor indivíduo da população ao longo de 200 gerações para uma execução do AG. No gráfico à esquerda, estão representados o pior indivíduo da po-


pulação em vermelho, a mediana em amarelo e a solução incumbente em azul, já no gráfico à direita são representados apenas a mediana e a solução incumbente, mas com maior resolução no valor da função objetivo. A Figura 40 ilustra a trajetória de convergência da solução incumbente de 8 execuções do AG.

Figura 39: Convergência da função objetivo para a alocação de BCs no sistema de 23 nós com GD considerando as duas parcelas da função objetivo.



Fonte: Elaborada pelo autor.

Figura 40: Convergência de 8 execuções da função objetivo para a alocação de BCs no sistema de 23 nós com GD considerando as duas parcelas da função objetivo.



Fonte: Elaborada pelo autor.

A partir da Figura 40 e dos resultados mostrados no histograma da Figura 38, observa-se um aumento considerável na ocorrência de mínimos locais.⁵ Entre as

⁵vale lembrar que é realizada uma busca local nos três indivíduos membros da elite, logo a solução mostrada sempre corresponde no mínimo a um mínimo local.

8 execuções representadas, duas soluções atingiram o patamar da melhor solução obtida com um menor número de gerações, escapando da convergência para mínimos locais. Pode-se perceber que as soluções requerem um maior número de gerações para a convergência da solução incumbente frente ao caso da Figura 33, onde foi considerada apenas a parcela de perdas.

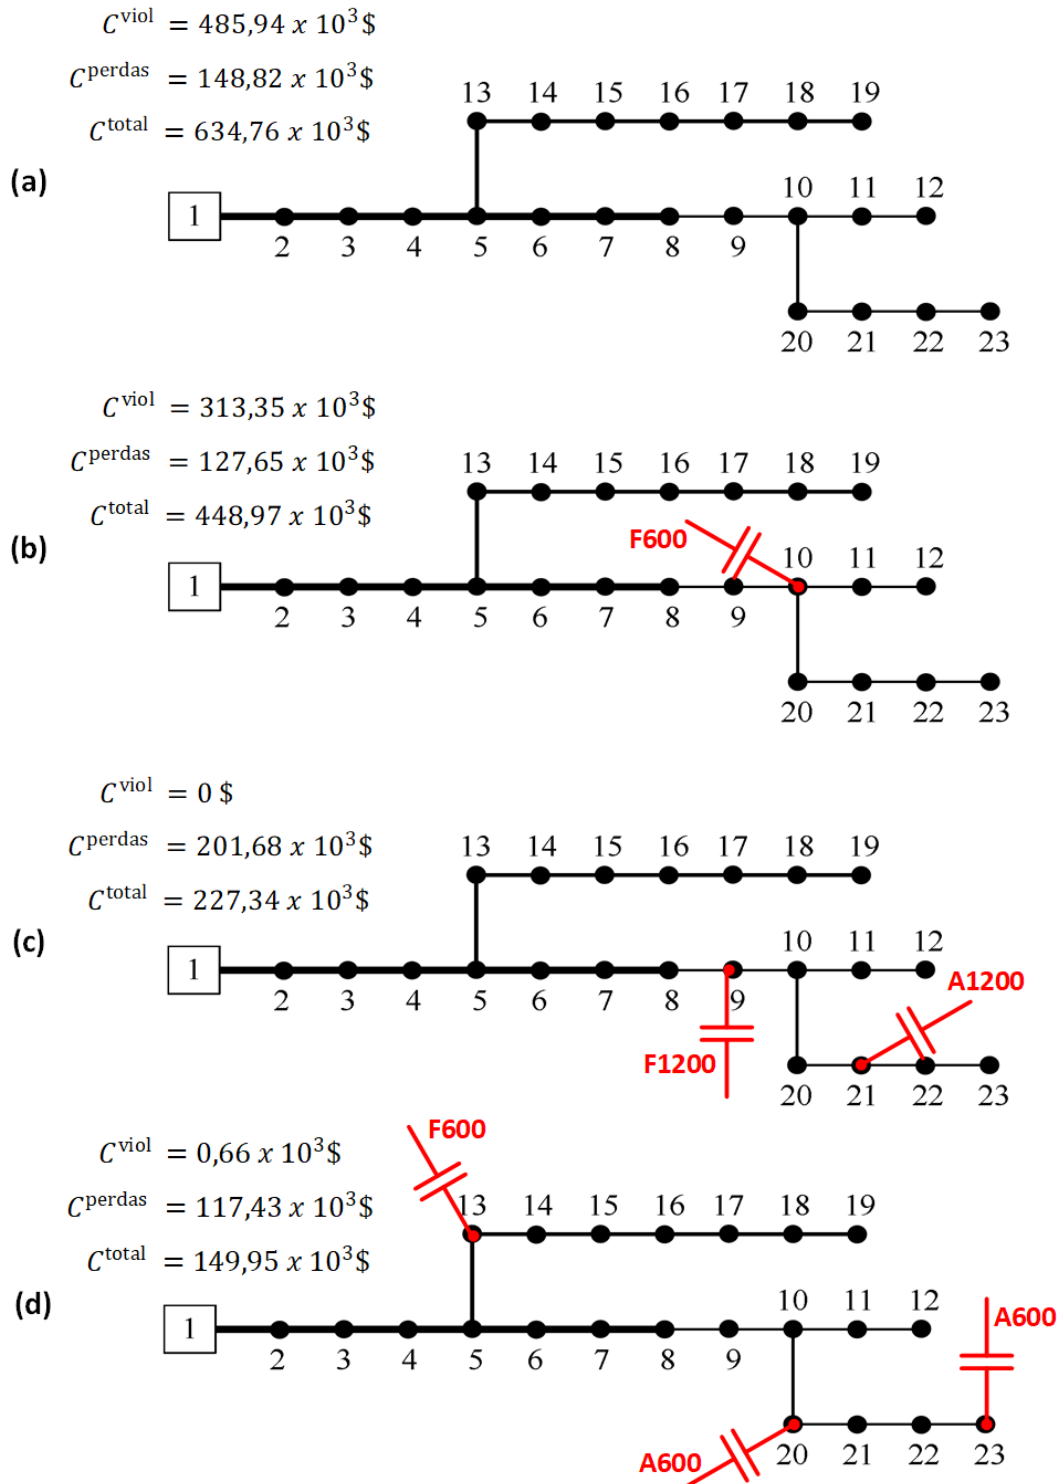
Embora as execuções mostradas na Figura 40 tenham convergido por vezes para soluções distintas, obtiveram valores muito próximos à melhor solução obtida, o que demonstra a eficácia do algoritmo proposto na obtenção de boas soluções, mesmo com um incremento considerável de não-convexidades na função objetivo pela consideração dos custos referentes tanto às perdas quanto às violações de tensão.

5.2.4 Alocação de BCs - Comparação dos resultados

De forma a comparar os resultados obtidos pelos diferentes casos analisados na Seção 5.2, são apresentados na Figura 41 os resultados da alocação de BCs no sistema de 23 nós para os casos onde há a presença de GDs. São representados os BCs alocados por nó, denotados pelo tipo e potência instalada, além dos custos referentes às perdas, violações de tensão e os custos totais, que incluem os custos de investimento e os custos de operação. A Figura 41(a) representa o caso base do sistema de 23 nós, onde não há alocação de BCs. As Figuras 41(b), (c) e (d) representam a alocação de BCs ao considerar apenas a parcela de perdas, apenas a parcela de violações nos níveis de tensão e as duas parcelas da função objetivo, respectivamente. Cabe salientar que nas Figuras 41(b) e (c), embora o custo de apenas uma das parcelas tenha sido considerado na otimização do problema, são representados as duas parcelas como forma de comparação.

A partir dos resultados obtidos, pode-se perceber a considerável redução dos custos totais nos diferentes casos analisados frente ao caso base representado na Figura 41(a). Na Figura 41(b), foi priorizada a minimização do custo das perdas somado aos custos de instalação e operação dos BCs. Por esse fato, foi alocado apenas um BC de 600 kvar, o que reduziu as perdas frente ao caso base, mas manteve elevado o custo referentes às violações de tensão. Na Figura 41(c), o custo das violações de tensão foi minimizado a um valor nulo, no entanto, houve um considerável aumento no custo das perdas do sistema, de aproximadamente 35% frente ao caso base. Já

Figura 41: Comparação dos resultados obtidos para o sistema de 23 nós com GD, para: (a) caso base, (b) somente perdas, (c) somente violações de tensão, (d) perdas e violações de tensão.



Fonte: Elaborada pelo autor.

na Figura 41(d), embora o custo das perdas tenha sido inferior ao caso da Figura 41(b), houve um aumento nos custos de instalação e manutenção dos 3 BCs alocados. Este fato propiciou a redução do custo das violações de tensão para um valor praticamente nulo e a obtenção do menor custo total entre os casos analisados.

Nos casos onde houve a alocação de BCs, pode-se perceber que os locais de instalação e as capacidades instaladas variaram conforme o objetivo analisado, o que evidencia a influência das parcelas da função objetivo na obtenção do custo total da alocação dos BCs.

6 CONCLUSÕES

Neste trabalho, foi apresentado um modelo de planejamento da expansão de SDEE, considerando a compensação de potência reativa através da alocação ótima de BCs fixos e automáticos. O modelo proposto simula a operação cronológica do sistema, sendo possível obter o modo ótimo de operação dos BCs automáticos para todas as formas diárias de operação previstas pelos cenários representativos.

Foi apresentada também, a formulação para o cálculo das grandezas de interesse, sendo elas as perdas de energia e as violações dos limites de tensão. O modelo foi implementado com a integração dos softwares MATLAB e OpenDSS, o que forneceu uma aplicação robusta com a obtenção de resultados adequados ao modelo proposto.

A formulação proposta é abrangente, permitindo considerar a contribuição das GDs na solução do problema de otimização. Deve-se destacar também a flexibilidade da codificação implementada para a otimização pelo AG, capaz de ser adaptada em função das necessidades e critérios de planejamento adotados.

As análises realizadas abrangeram duas situações: (i) validação dos cenários representativos de operação e (ii) alocação de compensação de potência reativa considerando as duas parcelas da função objetivo, com ou sem a inclusão de GDs.

Todos os resultados da validação dos cenários representativos e da alocação ótima de BCs foram comparados com os resultados obtidos pelo modo exato de operação horária do sistema, que é diferenciado para todos os dias do ano (8760h).

Na validação dos \mathcal{K} cenários representativos, observou-se que um número reduzido de cenários é suficiente para representar o comportamento da carga e da GD. Pelo fato das perdas de energia terem comportamento sistêmico, estas podem ser mais representativas no comportamento médio do sistema do que no individual em um nó específico. Com isso, ao comparar os valores obtidos pelos cenários represen-

tativos e os obtidos pelo modo exato de operação do sistema, a diferença de valores foi muito pequena. Já as violações nos níveis de tensão, usualmente têm um maior peso individual sobre cada nó, o que gera uma pequena diferença entre os valores obtidos pelos cenários representativos frente aos valores obtidos pelos 365 dias do ano conforme os casos analisados.

Na geração de cenários combinatórios de carga-GD, os cenários não tem a necessidade de ter sincronismo nos dados, podendo representar dados diferentes para períodos diferentes, de acordo com suas probabilidades de ocorrência.

Com isso, foi demonstrado o potencial de aplicação de cenários para a representação de curvas de carga representativas e de curvas de geração fotovoltaica. Nos testes realizados, observou-se que 3 cenários representativos da carga e 3 cenários representativos da GD se mostraram suficientes para representar a operação do sistema com boa ponderação entre precisão e esforço computacional.

O modelo de alocação de BCs proposto se mostrou mais convexo quando é considerada apenas uma das parcelas da função objetivo, apenas perdas ou apenas violações nos níveis de tensão. Quando ambas parcelas são consideradas, observou-se um aumento expressivo no número de mínimos locais, oriundos de soluções bastante diferentes, mas mesmo assim, com valores para a função objetivo diferindo menos de 4% entre a melhor e a pior solução obtida.

O sistema de 23 nós, apesar de pequeno, possui graves problemas de tensão em seu caso base e uma distribuição uniforme da carga, tornando o problema da minimização de perdas e violação dos limites de tensão mais difícil de ser resolvido. Por mais que o presente trabalho tenha sido aplicado a um sistema de distribuição específico, o modelo proposto é flexível e pode ser aplicado a outros sistemas.

A robustez da implementação especializada baseada na meta-heurística AG, permitiu incluir explicitamente parte das restrições do modelo proposto para a alocação de BCs, obtendo assim boas soluções com um reduzido número de gerações. A inclusão de um controle de diversidade explícito e busca local, contribuiriam também para a qualidade dos resultados obtidos.

Os resultados mostrados neste trabalho comprovam que a consideração de incertezas é muito importante para caracterizar a operação de SDEE, pois as incertezas associadas ao comportamento da carga e da GD fazem parte da realidade das redes

elétricas. Cabe salientar também que a aleatoriedade e a quantidade de cenários representativos aumentam com a inserção de GDs. Tendo em vista estes aspectos, a avaliação probabilística da operação torna-se vantajosa ao fornecer mais informações do que a análise determinística tradicional.

6.1 Trabalhos futuros

Embora o método proposto se apresente como uma ferramenta útil na avaliação da expansão de SDEE com uma abordagem probabilística, existem aspectos que podem ser aperfeiçoados. São sugeridas as seguintes extensões do modelo proposto:

- aplicação do modelo em outras redes de distribuição, a fim de validar a robustez e a flexibilidade de aplicação do modelo de alocação ótima de BCs;
- quando existir disponibilidade de dados confiáveis, o modelo proposto pode ser estendido para horizontes maiores, considerando mais de um momento de realização dos investimentos;
- realizar testes considerando o crescimento da carga no horizonte de planejamento proposto;
- inclusão de incertezas provenientes de outras fontes de GD (eólica ou micro-turbinas), do armazenamento de energia e do preço da energia;
- inclusão de outros modos de controle para os BCs;
- utilização de uma resolução mais detalhada para permitir observar variações na tensão dentro do tempo regulamento pela ANEEL (10 minutos).

REFERÊNCIAS

AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **PRODIST Módulo 8**: procedimentos de distribuição de energia elétrica no sistema elétrico nacional - qualidade da energia elétrica. Brasília: ANEEL, 2018.

ASSIS, F. A. et al. Transmission expansion planning with wind sources based on constructive metaheuristics. In: SIMPOSIO BRASILEIRO DE SISTEMAS ELETRICOS (SBSE), 7., 2018, Niterói. **Proceedings...** Niterói: SBA, 2018. p.1–6.

ATWA, Y. M.; EL-SAADANY, E. F. Probabilistic approach for optimal allocation of wind-based distributed generation in distribution systems. **IET Renewable Power Generation**, London, v.5, n.1, p.79–88, 2011.

BAGHERI, A.; MONSEF, H.; LESANI, H. Integrated distribution network expansion planning incorporating distributed generation considering uncertainties, reliability, and operational conditions. **International Journal of Electrical Power & Energy Systems**, London, v.73, p.56–70, 2015.

BARAN, M.; WU, F. F. Optimal sizing of capacitors placed on a radial distribution system. **IEEE Transactions on Power Delivery**, New York, v.4, n.1, p.735–743, Jan. 1989.

BARBOSA, T. M.; RICCIARDI, T. R.; FREITAS, W. Obtenção e aplicação de curvas de carga representativas utilizando clusterização ou cadeia de markov. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 22., 2018, João Pessoa. **Proceedings...** João Pessoa: SBA, 2018. p.1–6.

BIDOKI, S. M. et al. Evaluating different clustering techniques for electricity customer classification. In: IEEE PES TRANSMISSION AND DISTRIBUTION CONFERENCE AND EXPOSITION, 2010, New Orleans. **Proceedings...** New York: IEEE, 2010. p.1–5.

BONGERS, T. et al. Robust high voltage network expansion planning considering multiple future renewable scenarios. In: IEEE INTERNATIONAL ENERGY CONFERENCE (ENERGYCON), 2016, Leuven, Belgium. **Proceedings...** New York: IEEE, 2016. p.1–6.

BOONE, G.; CHIANG, H.-D. Optimal capacitor placement in distribution systems by genetic algorithm. **International Journal of Electrical Power & Energy Systems**, London, v.15, n.3, p.155 – 161, 1993.

BORGES, C. L. T.; MARTINS, V. F. Multistage expansion planning for active distribution networks under demand and distributed generation uncertainties. **International Journal of Electrical Power & Energy Systems**, London, v.36, n.1, p.107–116, 2012.

- BRADLEY, P. S. et al. Scaling clustering algorithms to large databases. In: INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 4., 1998, New York. **Proceedings...** New York: AAAI Press, 1998. p.9–15.
- CENTRO DE REFERÊNCIA PARA ENERGIA SOLAR E EÓLICA SÉRGIO SALVO BRITO. **Base de Dados de radiação solar incidente**. Rio de Janeiro: CRESESB, 2018.
- CHIANG, H. et al. Optimal capacitor placements in distribution systems. I. A new formulation and the overall problem. **IEEE Transactions on Power Delivery**, New York, v.5, n.2, p.634–642, 1990.
- CHIANG, H. et al. Optimal capacitor placements in distribution systems. II. Solution algorithms and numerical results. **IEEE Transactions on Power Delivery**, New York, v.5, n.2, p.643–649, 1990.
- COOK, R. F. Analysis of capacitor application as affected by load cycle. **IEEE Transactions on Power Apparatus and Systems**, New York, v.78, n.3, p.950–956, Apr. 1959.
- COOK, R. F. Optimizing the application of shunt capacitors for reactive-volt-ampere control and loss reduction. **IEEE Transactions on Power Apparatus and Systems**, New York, v.80, n.3, p.430–441, Apr. 1961.
- GRAINGER, J. J.; LEE, S. H. Optimum size and location of shunt capacitors for reduction of losses on distribution feeders. **IEEE Transactions on Power Apparatus and Systems**, New York, v.100, n.3, p.1105–1118, Mar. 1981.
- GRAINGER, J. J.; LEE, S. h. Capacity release by shunt capacitor placement on distribution feeders: a new voltage-dependent model. **IEEE Transactions on Power Apparatus and Systems**, New York, v.101, n.5, p.1236–1244, May 1982.
- HAFFNER, S. et al. Multistage model for distribution expansion planning with distributed generation - part I: problem formulation. **IEEE Transactions on Power Delivery**, New York, v.23, n.2, p.915–923, Apr. 2008.
- HAFFNER, S. et al. Alocação de bancos de capacitores em redes de distribuição de energia visando eliminar violações de tensão. **SBA Controle & Automação**, Campinas, v.20, n.4, p.546–563, 2009.
- HAFFNER, S.; PEREIRA, L. A.; PEREIRA, L. F. A. A method for optimization of five-phase induction machines based on genetic algorithms. **Journal of Control, Automation and Electrical Systems**, Campinas, v.26, n.5, p.521–534, Oct. 2015.
- HAGHIFAM, M. R.; MALIK, O. P. Genetic algorithm-based approach for fixed and switchable capacitors placement in distribution systems with uncertainty and time varying loads. **IET Generation, Transmission & Distribution**, London, v.1, n.2, p.244–252, Mar. 2007.
- HAQUE, M. Capacitor placement in radial distribution systems for loss reduction. **IEE Proceedings-Generation, Transmission and Distribution**, London, v.146, n.5, p.501–505, 1999.
- JAIN, A. K. Data clustering: 50 years beyond k-means. **Pattern Recognition Letters**, Amsterdam, v.31, n.8, p.651 – 666, 2010.

- JAIN, N.; SINGH, S.; SRIVASTAVA, S. PSO based placement of multiple wind DGs and capacitors utilizing probabilistic load flow model. **Swarm and Evolutionary Computation**, Amsterdam, v.19, p.15 – 24, 2014.
- JANNAT, M. B.; SAVIC, A. S. Optimal capacitor placement in distribution networks regarding uncertainty in active power load and distributed generation units production. **IET Generation, Transmission and Distribution**, London, v.10, n.12, p.3060–3067, 2016.
- KANWAR, N. et al. Optimal distributed resource planning for microgrids under uncertain environment. **IET Renewable Power Generation**, London, v.12, n.2, p.244–251, 2017.
- KAVOUSHI-FARD, A.; NIKNAM, T. Considering uncertainty in the multi-objective stochastic capacitor allocation problem using a novel self adaptive modification approach. **Electric Power Systems Research**, Switzerland, v.103, p.16 – 27, 2013.
- LAUTENSCHLEGER, A. H. **Análise da operação de sistemas de distribuição considerando as incertezas da carga e da geração distribuída**. 2018. 109 p. Dissertação (Mestrado em Engenharia Elétrica) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018.
- LEE, S. H.; GRAINGER, J. J. Optimum placement of fixed and switched capacitors on primary distribution feeders. **IEEE Transactions on Power Apparatus and Systems**, New York, v.100, n.1, p.345–352, Jan. 1981.
- LI, J. et al. Robust coordinated transmission and generation expansion planning considering ramping requirements and construction periods. **IEEE Transactions on Power Systems**, New York, v.33, n.1, p.268–280, Jan. 2018.
- LIKAS, A.; VLASSIS, N.; VERBEEK, J. J. The global k-means clustering algorithm. **Pattern Recognition Letters**, Amsterdam, v.36, n.2, p.451–461, 2003.
- MACQUEEN, J. Some methods for classification and analysis of multivariate observations. In: BERKELEY SYMPOSIUM ON MATHEMATICAL STATISTICS AND PROBABILITY, 5., 1967, Berkeley. **Proceedings...** Berkeley: University of California Press, 1967. p.281–297.
- MAHMOUDI-KOHAN, N.; MOGHADDAM, M. P.; BIDOKI, S. M. Evaluating performance of WFA k-means and modified follow the leader methods for clustering load curves. In: IEEE/PES POWER SYSTEMS CONFERENCE AND EXPOSITION, 2009, Seattle. **Proceedings...** New York: IEEE, 2009. p.1–5.
- MONTICELLI, A. J. **Fluxo de carga em redes de energia elétrica**. São Paulo: Edgard Blucher, 1983.
- MUKHERJEE, M.; GOSWAMI, S. Solving capacitor placement problem considering uncertainty in load variation. **Electrical Power and Energy Systems**, London, v.62, p.90 – 94, 2014.
- NAJAFI, A. et al. Capacitor placement in distorted distribution network subject to wind and load uncertainty. **Journal of Operation and Automation in Power Engineering**, Iran, v.4, n.2, p.153–164, 2016.
- NEAGLE, N. M.; SAMSON, D. R. Loss reduction from capacitors installed on primary feeders. **IEEE Transactions on Power Apparatus and Systems**, New York, v.75, n.3, p.950–959, Jan. 1956.

OSKUEE, M. J. R.; MILANI, K. R.; RAVADANEGH, S. N. Multi-objective planning of capacitors in distribution networks with consideration of uncertainties. In: INTERNATIONAL COMPREHENSIVE COMPETITION CONFERENCE ON ENGINEERING SCIENCES, 1., 2016, Anzali. **Proceedings...** Anzali: ICES, 2016. p.31–35.

PEREIRA JR, B. **Alocação otimizada de bancos de capacitores em sistemas de distribuição de energia elétrica através de metaheurísticas multiobjetivo**. 2009. 193 p. Dissertação (Mestrado em Engenharia Elétrica) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade Estadual Paulista, Iha Solteira, 2009.

PFENNINGER, S.; STAFFELL, I. Long-term patterns of European PV output using 30 years of validated hourly reanalysis and satellite data. **Energy**, Denmark, v.114, p.1251–1265, 2016.

RAJU, G. K. V.; BIJWE, P. R. Reactive power/voltage control in distribution systems under uncertain environment. **IET Generation, Transmission & Distribution**, London, v.2, p.752–763, Sept. 2008.

RAVADANEGH, S. N.; OSKUEE, M. R. J.; KARIMI, M. Multi-objective planning model for simultaneous reconfiguration of power distribution network and allocation of renewable energy resources and capacitors with considering uncertainties. **Journal of Central South University**, China, v.24, n.8, p.1837–1849, Aug. 2017.

RAVINDRA, K.; JAYARAM, K. Multi-Objective approach for capacitor placement considering uncertainty using point estimate method. In: IEEE REGION 10 SYMPOSIUM (TENSYP), 2017, Cochin, India. **Proceedings...** New York: IEEE, 2017. p.1–5.

RESENER, M. **Modelo linearizado para problemas de planejamento da expansão de sistemas de distribuição**. 2016. 198 p. Tese (Doutorado em Engenharia Elétrica) — Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016.

RESENER, M. et al. Mixed-integer LP model for volt/var control and energy losses minimization in distribution systems. **Electric Power Systems Research**, Switzerland, v.140, p.895 – 905, 2016.

SCHMILL, J. V. Optimum size and location of shunt capacitors on distribution feeders. **IEEE Transactions on Power Apparatus and Systems**, New York, v.84, n.9, p.825–832, Sept. 1965.

SINGH, C.; KIM, Y. An efficient technique for reliability analysis of power systems including time dependent sources. **IEEE Transactions on Power Systems**, New York, v.3, n.3, p.1090–1096, Aug. 1988.

ZALIK, K. R. An efficient k-means clustering algorithm. **Pattern Recognition Letters**, Amsterdam, v.29, n.9, p.1385 – 1391, 2008.

ZEINALZADEH, A.; MOHAMMADI, Y.; MORADI, M. H. Optimal multi objective placement and sizing of multiple DGs and shunt capacitor banks simultaneously considering load uncertainty via MOPSO approach. **Electrical Power and Energy Systems**, London, v.67, p.336 – 349, 2015.